

## Repositório ISCTE-IUL

---

Deposited in *Repositório ISCTE-IUL*:

2021-12-09

Deposited version:

Accepted Version

Peer-review status of attached file:

Peer-reviewed

Citation for published item:

Fernandes, S., Laureano, R. M. S., Abrantes, C. & Laureano, L. M. S. (2021). Detecção de manipulação de resultados e seu impacto nos fundos europeus: Uma abordagem analítica. In Rocha, A., Gonçalves, R., Penalvo, F. G., & Martins, J. (Ed.), 2021 16th Iberian Conference on Information Systems and Technologies (CISTI). Chaves: IEEE.

Further information on publisher's website:

[10.23919/CISTI52073.2021.9476453](https://doi.org/10.23919/CISTI52073.2021.9476453)

Publisher's copyright statement:

This is the peer reviewed version of the following article: Fernandes, S., Laureano, R. M. S., Abrantes, C. & Laureano, L. M. S. (2021). Detecção de manipulação de resultados e seu impacto nos fundos europeus: Uma abordagem analítica. In Rocha, A., Gonçalves, R., Penalvo, F. G., & Martins, J. (Ed.), 2021 16th Iberian Conference on Information Systems and Technologies (CISTI). Chaves: IEEE., which has been published in final form at <https://dx.doi.org/10.23919/CISTI52073.2021.9476453>. This article may be used for non-commercial purposes in accordance with the Publisher's Terms and Conditions for self-archiving.

---

### Use policy

Creative Commons CC BY 4.0

The full-text may be used and/or reproduced, and given to third parties in any format or medium, without prior permission or charge, for personal research or study, educational, or not-for-profit purposes provided that:

- a full bibliographic reference is made to the original source
- a link is made to the metadata record in the Repository
- the full-text is not changed in any way

The full-text must not be sold in any format or medium without the formal permission of the copyright holders.

---

# Deteção de manipulação de resultados e seu impacto nos fundos europeus: uma abordagem analítica

## *Earnings management detection and its impact on european funds: a data analytics approach*

Susana Fernandes  
Raul M. S. Laureano  
Instituto Universitário de Lisboa (ISCTE-IUL),  
Lisboa, Portugal  
BRU-IUL e ISTAR-IUL, Lisboa, Portugal  
Av. das Forças Armadas, Lisboa  
1649-026 Lisboa, Portugal  
[susana.fernandes@iscte-iul.pt](mailto:susana.fernandes@iscte-iul.pt)  
[raul.laureano@iscte-iul.pt](mailto:raul.laureano@iscte-iul.pt)

Catarina Abrantes  
Luís M. S. Laureano  
Instituto Universitário de Lisboa (ISCTE-IUL),  
Lisboa, Portugal  
BRU-IUL, Lisboa, Portugal  
Av. das Forças Armadas, Lisboa  
1649-026 Lisboa, Portugal  
[catarina\\_abrantes@iscte-iul.pt](mailto:catarina_abrantes@iscte-iul.pt)  
[luis.laureano@iscte-iul.pt](mailto:luis.laureano@iscte-iul.pt)

**Resumo** — Portugal nos próximos anos vai receber, 66,2 mil milhões de euros da União Europeia, sendo 45 mil milhões para atenuar o impacto da pandemia na economia e 21,2 mil milhões do próximo quadro comunitário 2021-2027. Mas o sucesso da atribuição dos fundos europeus às PME e o impacto na economia continua a estar em debate, tornando-se urgente encontrar soluções eficientes e eficazes para o benefício da economia portuguesa. Assim, como podem as técnicas analíticas de deteção de manipulação de resultados e de análise preditiva beneficiar o processo de atribuição de fundos financeiros às PME portuguesas? Para responder à questão utilizou-se o modelo *M-Score* de Beneish combinado com árvores de classificação (CART e CHAID) com o objetivo de prever o sucesso dos projetos financiados por fundos da União Europeia. Os resultados são promissores, ao identificar como bons preditores do sucesso dos projetos de investimentos das PME, à data da candidatura, os índices *M-Score*. Assim, os organismos gestores dos fundos europeus ganham *insights* relativos à importância que a manipulação de resultados pode ter na aprovação das candidaturas de projetos, mas não se refletindo, posteriormente, esse financiamento em projetos de sucesso.

**Palavras Chave** – Manipulação de Resultados; *M-Score* Beneish; Árvores Decisão; Fundos Europeus; PME.

**Abstract** — Portugal will receive €66.2 billion from the European Union in the coming years, with €45 billion to mitigate the impact of the pandemic on the economy and €21.2 billion from the next Community framework 2021-2027. But the success of allocating European funds to SMEs and the impact on the economy remains under discussion, making it urgent to find efficient and effective solutions for the benefit of the Portuguese economy. Thus, how can the earnings management combined with Analytics techniques benefit the process of allocating financial funds to Portuguese SMEs? To answer the question formulated, the Beneish *M-Score* model was used, in combination with data analysis and Decision Trees - CART and CHAID, with the objective of predicting the success of projects to European Union funds. The results are promising, by identifying as good predictors the Beneish *M-Score*

indices of the success of SME investment projects at the time of application. Thus, the management bodies of the European funds gain insights into the importance that the manipulation of results can have in the approval of project applications, but not if it is subsequently reflected in this funding in successful projects.

**Keywords** – Earnings Management; *M-Score* Beneish; Decision Trees; European Funds; SME.

### I. INTRODUÇÃO

Portugal a partir de 2021, com o próximo quadro comunitário 2021-2027 e em conjunto com os fundos europeus para a recuperação da economia, a “Bazuca Europeia”, vai receber a maior ajuda financeira, no mais curto espaço de tempo, desde a sua adesão à União Europeia (UE). Até ao ano de 2020, através dos sucessivos quadros comunitários de apoio, Portugal beneficiou de mais de 132 mil milhões de euros, num período de 35 anos, o que representa entre dois a três por cento do Produto Interno Bruto (PIB) português ao longo desses anos [1]. No entanto, é frequente colocar-se em causa a eficácia da utilização dos fundos, uma vez que Portugal se posiciona entre os países com menor índice de implementação das estratégias da Europa 2020 [2]. Adicionalmente, sugere-se que a falta de eficácia na atribuição dos fundos centra-se no facto de as candidaturas a estes programas requererem o cumprimento de determinados requisitos [3]. De facto, por vezes, as empresas não conseguem atingir nos prazos destinados, levando à suspeição que estas possam ter a tentação de manipular os seus resultados [4][5], de forma a cumprirem todos os requisitos e assim beneficiarem dos fundos europeus.

Para evitar o mau uso dos dinheiros públicos europeus, a Comissão Europeia desenvolveu uma estratégia operacional de combate à fraude e um sistema de deteção precoce e de exclusão, que com o apoio de um painel interinstitucional decide sobre a exclusão de operadores económicos do financiamento da UE, devido a fraude ou corrupção [5]. No entanto, estudos recentes,

publicados pelo organismo responsável por controlar a utilização dos fundos da UE, concluem que a Comissão Europeia não possui informação abrangente sobre a dimensão, a natureza e as causas da fraude, para além de nunca ter efetuado qualquer avaliação relativa a fraude não detetada [5].

Em Portugal, os organismos intermédios de programas, com destaque para a AICEP (Agência para o Investimento e Comercio Externo de Portugal) e IAPMEI (Agência para a Competitividade e Inovação), têm como tarefas a análise dos processos de candidatura, a decisão de atribuição de apoio financeiro e a verificação dos incentivos, como também a identificação de situações irregulares, que pode ter por base a manipulação de resultados (MR), com efeitos nas declarações e formulários das candidaturas [4][5].

Na Figura 1 apresenta-se o processo de atribuição de incentivos financeiros, destacando-se as fases: i) análise da candidatura com decisão de atribuição de apoio, ii) execução do projeto, nomeadamente até atingir o ano de cruzeiro, e iii) o encerramento. Neste estudo, são alvo de análise o momento em que a candidatura é apresentada e, também, o momento em que o projeto termina e é avaliado. Esta investigação pretende culminar num modelo de *scoring* de risco de uma candidatura, que tem por base o diagnóstico da MR e outras características do promotor e da candidatura, ajudando os organismos intermédios a selecionar as candidaturas com maior probabilidade de sucesso (*Score* de sucesso > 0,5).



Figura 1: Fases do processo de atribuição de incentivos, percorridas ao longo dos anos do projeto Fonte: AICEP [3]

Neste contexto, é importante detetar a MR, que pode, nas situações mais graves, traduzir uma fraude, nas declarações financeiras sujeitas a análise por parte destes organismos.

A MR é uma questão complexa, identificada e interpretada em função das diferentes perceções dos investigadores [6]. Apesar de não existir uma definição consensual, a mais utilizada considera a MR como um processo onde deliberadamente, e de acordo com os princípios contabilísticas, se fazem opções de modo a alcançar um determinado nível de resultados [7] ou para modificar a perceção do desempenho da empresa contida na informação financeira reportada aos seus utilizadores [8].

No entanto, importa indicar duas perspetivas sobre MR [9]. Por um lado, a vertente oportunista, na qual os gestores têm o objetivo claro de adulterar as demonstrações financeiras em prol de si mesmos. Por outro, a distorção informativa, onde os gestores alteram as demonstrações financeiras de modo a transmitirem as suas perspetivas privadas sobre o desempenho futuro da empresa, com intenção de gerar conteúdo informativo de maior qualidade.

As diferentes identificações e interpretações deram origem diferentes métodos de deteção de MR, sendo o mais difundido

na literatura o método baseado em *accruals*, onde estes resultam do desencontro entre o momento do fluxo de caixa e o momento do reconhecimento do resultado operacional [6], e que têm sido utilizados com sucesso [10].

Apesar da vasta literatura e das evidências dos benefícios das técnicas de MR trazem para o processo de tomada de decisão, estas técnicas ainda não foram aplicadas, pelos organismos responsáveis pela análise e verificação de candidaturas, aos incentivos financeiros. Assim, coloca-se a questão: como podem as técnicas analíticas de deteção de MR e de análise preditiva beneficiar o processo de atribuição de fundos financeiros às PME portuguesa?

De facto, no âmbito da avaliação da aplicação dos incentivos financeiros às PME, em Portugal, verifica-se que algumas das empresas elegíveis e com contratos de apoio financeiro assinados acabam por não cumprir com o inicialmente contratado, originando a anulação desses contratos, com a consequente devolução do incentivo concedido. Este problema, por um lado, vai originar custos administrativos, ou mesmo judiciais, para o Estado Português. Por outro lado, impedem o acesso das empresas, que apesar de elegíveis, não foram apoiadas porque o orçamento do programa de incentivos foi esgotado. Assim, o deficitário aproveitamento do apoio estrutural prende-se com o sucesso dos projetos aprovados, ou seja, as empresas têm uma menor propensão para atingir o sucesso do projeto se, anteriormente, alteraram a sua informação financeira [3]. Neste sentido, é expectável que as empresas que mais fielmente espelham os seus resultados, à data da candidatura, tenham maior probabilidade de atingir o sucesso da mesma.

## II. A UTILIZAÇÃO DE MANIPULAÇÃO DE RESULTADOS

Na literatura, muitos são os estudos que procuram mensurar a prática de MR, com recurso aos métodos baseados nas variações do capital circulante, também denominados de modelos baseados em *accruals* (MBA) [6]. Estes têm por base a decomposição dos *accruals* totais (TA) diretamente mensurados a partir das demonstrações financeiras, nas suas componentes discricionárias e não discricionárias. Desta forma, é necessário que os modelos criados procurem explicar e quantificar os *accruals* não discricionários (AND) e, através da diferença entre o TA e os AND, possam ser mensurados os *accruals* discricionários (AD), ou seja, aqueles que são passíveis de MR [12]. McNichols, no seu estudo sobre MR utilizando o método baseado em *accruals*, identifica dois tipos de abordagens para a deteção da mesma [11]. A primeira é através de modelos baseados em *accruals* agregados, que procuram estimar a componente discricionária dos *accruals* vistos de uma forma agregada (e.g., modelo de Jones [12] e suas variantes [13][15]). A segunda centra-se em modelos baseados em *accruals* específicos, que consiste em identificar ou fazer uma modelação específica de *accruals*, tendo como objetivo analisar o comportamento das variáveis independentes que influenciam a prática de MR (e.g., modelo de Beneish) [14].

### A. Original Jones Model

O modelo de Jones [12] procura captar o efeito das circunstâncias económicas da empresa, sendo os *accruals* determinados em função da variação do volume de negócios da empresa e do seu ativo fixo tangível.

$$TA_{i,t} = \alpha_0 + \alpha_1 \frac{1}{A_{i,t-1}} + \alpha_2 \Delta REV_{i,t} + \alpha_3 PPE_{i,t} + \varepsilon_{i,t} \quad (1)$$

Onde:

$TA_{i,t}$  – *Accruals* totais da empresa  $i$  no período  $t$ ;

$\Delta REV_{i,t}$  – Variação das vendas da empresa  $i$  no período  $t$ ;

$A_{i,t-1}$  – Valor total do ativo da empresa  $i$  no período  $t-1$ ;

$PPE_{i,t}$  – Ativo fixo tangível da empresa  $i$  no período  $t$ ;

$\varepsilon_{i,t}$  – Erro aleatório, ou seja, tudo o que não é explicado pelo modelo, da empresa  $i$  no período  $t$ .

As limitações apontadas ao modelo residem na incapacidade do modelo captar o impacto das manipulações nas vendas, por este assumir que estão associadas a AND [13].

#### B. Modelo de Modified Jones Model – Dechow

Assim, surge uma versão modificada do modelo de Jones com o intuito de eliminar a fonte de erro existente [13]. Ou seja, tem o intuito de retirar o efeito do crescimento das vendas a crédito, considerando-a discricionário. No entanto, não soluciona o problema para o qual foi criado, pois poderá revelar-se inadequado em certas circunstâncias.

$$TA_{i,t} = \alpha_0 + \alpha_1 \frac{1}{A_{i,t-1}} + \alpha_2 (\Delta REV_{i,t} - \Delta AR_{i,t}) + \alpha_3 PPE_{i,t} + \varepsilon_{i,t} \quad (2)$$

Onde:

$\Delta AR_{i,t}$  – variação das contas a receber da empresa  $i$  no período  $t$ .

#### C. Modified Jones Model with ROA – Kothari

Desta forma, surge outra variante ao modelo de Jones, em que é considerada o desempenho da empresa. Assim, a introdução do efeito da rentabilidade do ativo permite a comparabilidade entre empresas do mesmo sector [15].

$$TA_{i,t} = \alpha_0 + \alpha_1 \frac{1}{A_{i,t-1}} + \alpha_2 \Delta REV_{i,t} + \alpha_3 PPE_{i,t} + \alpha_4 \Delta ROA_{i,t} + \varepsilon_{i,t} \quad (3)$$

Onde:

$\Delta ROA_{i,t}$  – Rentabilidade líquida do ativo da empresa  $i$  no período  $t$ .

#### D. Beneish (1997)

O Modelo de Beneish [14] permite o estabelecimento de uma relação sistemática entre a probabilidade de manipulação e os dados das demonstrações financeiras selecionadas, onde é calculado um *score*, o *M-Score*, a partir da combinação linear de oito variáveis financeiras que, analisadas isoladamente, não têm grande significado, mas que, em conjunto, procuram estudar as empresas que têm uma maior propensão para manipularem os seus resultados [3].

O *M-Score* é obtido através da seguinte expressão [16]:

$$M - Score_{i,t} = -4.840 + 0.920 DSRI_{i,t} + 0.528 GMI_{i,t} + 0.404 AQI_{i,t} + 0.892 SGI_{i,t} + 0.115 DEPI_{i,t} - 0.172 S GAI_{i,t} + 4.679 TATA_{i,t} - 0.327 LVGI_{i,t} \quad (4)$$

As oito variáveis que contribuem para este modelo encontram-se descritas na Tabela I.

TABELA I. VARIÁVEIS CONSTITUINTES DO *M-SCORE* DE BENEISH

Variável	Expressão de cálculo
DSRI <i>Days Sales Receivable Index</i>	$\frac{AR_t / REV_t}{AR_{t-1} / REV_{t-1}}$
GMI <i>Gross Margin Index</i>	$\frac{REV_{t-1} / REV_{t-1}}{REV_t - COGS_t / REV_t}$
AQI <i>Asset Quality Index</i>	$\frac{1 - (Current\ assets_t + PPE_t) / AT_t}{1 - (Current\ assets_{t-1} + PPE_{t-1}) / AT_{t-1}}$
SGI <i>Sales Growth Index</i>	$\frac{REV_t}{REV_{t-1}}$
DEPI <i>Depreciation Index</i>	$\frac{Depreciation_{t-1} / (Depreciation_{t-1} + PPE_{t-1})}{Depreciation_t / (Depreciation_t + PPE_t)}$
SGAI <i>Sales, General, &amp; Administrative Expenses Index</i>	$\frac{SGA_t / REV_t}{SGA_{t-1} / REV_{t-1}}$
TATA <i>Total accruals to Total assets</i>	$\frac{(\Delta Current\ assets_t - \Delta Cash_t - (\Delta Current\ liabilities_t - \Delta Current\ maturities\ of\ long - term\ debt_t - \Delta Income\ tax\ payable_t) - Depreciation_t) / AT_t}{(Long - term\ debt_{t-1} + Current\ liabilities_{t-1}) / AT_{t-1}}$
LVGI <i>Leverage Index</i>	$\frac{(Long - term\ debt_t + Current\ liabilities_t) / AT_t}{(Long - term\ debt_{t-1} + Current\ liabilities_{t-1}) / AT_{t-1}}$

Fonte: Beneish (1999:27)

Notas: COGS corresponde aos custos dos bens vendidos (*cost of goods sold*); PPE refere-se ao ativo fixo tangível (*property, plant and equipment*); SGA corresponde a *Selling, General & Administrative Expense*.

As variáveis deste modelo têm como finalidade capturar as distorções dos dados refletidos nas demonstrações financeiras, tendo sido agrupadas por Beneish [16][17] em dois grupos distintos: indicadores de práticas de contabilidade agressiva (DSRI, DEPI e TATA) e indicadores de fraude (GMI, AQI, SGI, SGAI e LVGI).

O valor do *M-score* revela a existência ou não de MR. Um *M-score* superior a -1,78 indica que as empresas em estudo apresentam uma elevada probabilidade de manipularem as suas demonstrações financeiras, pelo que se o oposto se verificar a tendência é para que a empresa não seja considerada como manipuladora [18][19].

Em suma, conforme o objetivo da análise da MR, assim se opta pelos modelos de *accruals* agregados ou de *accruals* específicos.

### III. METODOLOGIA

Atendendo ao problema, e conhecidos os principais modelos para a identificação da MR, considera-se o modelo *M-Score* de Beneish como o mais adequado ao contexto dos fundos europeus. Adicionalmente, reconhece-se nas árvores de decisão a capacidade de facilmente explicar as suas previsões, pelo que se utilizam os algoritmos *Classification And Regression Trees* (CART) e *Chi-square Automatic Interaction Detector* (CHAID) (dos mais utilizados) para prever o sucesso dos projetos apoiados em função de variáveis caracterizadoras dos projetos e das empresas e do *M-Score* e seus oito indicadores. Assim, a análise quantitativa inclui dois níveis: i) caracterizar a relação entre manipulação de resultados e o sucesso dos projetos, e ii) criar um modelo preditivo do sucesso dos projetos.

#### A. Dados e amostra

Os dados foram cedidos pelo IAPMEI, entidade responsável por parte dos incentivos financeiros atribuídos às PME portuguesas, relativamente às candidaturas aos sistemas de incentivos para a inovação ou para a qualificação, do programa Portugal 2020, referente ao período 2015 a 2018, e à informação constante nas demonstrações financeiras, para os períodos 2011 a 2019. No entanto, como o sucesso apenas se avalia na data de encerramento (Figura I) apenas se consideram na amostra as candidaturas de projetos que já se encontram concluídos e

encerrados, aos quais se acrescentam os projetos que foram anulados após assinatura contratual, mas já com valores pagos. Adicionalmente, importa referir que foram excluídas as candidaturas que se encontravam duplicadas ou para as quais não foi possível obter informação financeira suficiente para a análise. Assim, a amostra válida corresponde a 554 projetos.

### B. Caracterização da amostra

As empresas promotoras dos projetos são pequenas (46,9%), médias (33,6%) ou microempresas (16,2%), sendo os investimentos efetuados maioritariamente no Norte (55,8%) e Centro (33,2%) do país e canalizados, principalmente, para os sectores da indústria (87,9%), serviços (5,4%) e comércio (3,1%).

### C. Variável dependente

O sucesso do projeto é classificado em sucesso, quando o projeto foi concluído (codificado como 1) e insucesso, quando o projeto foi anulado (codificado como 0). Na amostra verifica-se que a maioria dos projetos teve sucesso (61,6%, n=341). Este resultado leva a concluir que a taxa de insucesso é, ainda assim, bastante elevada (n=213).

### D. Variáveis independentes

As variáveis independentes do modelo preditivo do sucesso dividem-se em quatro dimensões (D1 a D4):

- **D1:** MR, tendo sido calculado o *M-Score* para o ano da candidatura (identificado com o prefixo N) e para o ano anterior à candidatura (identificado com o prefixo N1). Também se consideram para cada ano os oito indicadores financeiros que servem de base ao cálculo do *M-Score* e com base no valor de corte consideram-se as respetivas variáveis binárias que indicam se a empresa manipula os seus resultados (codificado com 1) ou não (codificado com 0);
- **D2:** Características demográficas da empresa, sendo selecionadas a dimensão (micro, pequena, média, não PME), sector (comércio, construção, indústria, serviços, transporte/logística, turismo e não disponível) e a região NUTS II da sede (Alentejo, Algarve, Centro, Lisboa e Vale do Tejo e Norte);
- **D3:** Características da candidatura, onde se incluem a região NUTS II do investimento, a duração do projeto (em meses), dois indicadores relacionados com o investimento e seu financiamento standardizados (*Z-score*), designadamente, o valor do investimento e o valor da despesa elegível, o logaritmo do valor do investimento, o peso do incentivo no total do investimento aprovado (em %), o peso do incentivo reembolsável no total do incentivo aprovado (em %), o peso do incentivo não reembolsável no total do incentivo aprovado (em %) e, por fim, se o investimento inclui formação profissional (o que acontece em 30,3% das candidaturas);
- **D4:** Análise oficial da candidatura, sendo incluído, apenas, o mérito da candidatura atribuído pelo organismo intermédio que analisa as candidaturas (escala de 3 a 5), que mede a ambição do projeto e o seu potencial para o desenvolvimento da economia.

### E. Técnicas de análise de dados

Todas as análises foram realizadas em programas IBM, nomeadamente, no SPSS Statistics 27 e no SPSS Modeler 18.2. Primeiro, os dados recolhidos foram analisados quanto à sua qualidade, nomeadamente quanto às não-respostas e à existência de *outliers*. Não se detetaram não-respostas (já se haviam excluído as candidaturas com informação em falta) e os *outliers*, identificados nos indicadores que formam o *M-score* de Beneish foram substituídos pelo valor médio  $\pm$  três desvios-padrão, consoante o valor fora do padrão se encontrasse acima ou abaixo desse padrão (técnica usual em estudos de contabilidade que recorrem a dados financeiros externos).

Tendo os dados validados, recorreu-se a técnicas de estatística descritiva para descrever o comportamento de cada uma das variáveis independentes. Posteriormente, e para melhor se perceber a relação entre a MR e o sucesso dos projetos, compararam-se as médias e as distribuições dos indicadores do *M-Score* entre os projetos com e sem sucesso, recorrendo-se, respetivamente, ao teste *t* e ao teste de Mann-Whitney (considerando um nível de significância de 0,05). Foram realizados ambos, essencialmente, para avaliar a robustez dos resultados.

Por fim, recorreu-se às árvores de classificação, com os algoritmos CART [22] e CHAID [23], para criar os modelos preditivos do sucesso dos projetos. Os algoritmos baseados em árvores de decisão revelam-se adequados ao problema em causa, já que os modelos obtidos com estes algoritmos são de fácil compreensão e, geralmente, produzem bons resultados, quando aplicados a dados financeiros [20][21]. Adicionalmente, para cada um deles aplicam-se diversas parametrizações, nomeadamente, quanto à profundidade máxima da árvore, ao número mínimo de casos nos nós pai e filhos, balanceamento (duplicando registos) e utilização de *ensembles*, nomeadamente *boosting* e *bagging* (*voting* como critério de classificação, isto é, selecionando a categoria que apresenta maior probabilidade mais vezes).

Optou-se por se criarem modelos, com cada um dos algoritmos, para diferentes conjuntos de variáveis. Primeiro, tendo apenas preditores relativos à MR nos dois anos, depois, a estes preditores, acrescentaram-se as variáveis demográficas das empresas candidatas. De seguida, acrescentaram-se os preditores relativos à candidatura e, no final, incluiu-se o mérito do projeto, o que já obriga a uma avaliação da candidatura pelo organismo público.

Em relação à avaliação de modelos de classificação existem diversas métricas de avaliação, tendo-se recorrido às mais utilizadas e baseadas na matriz de confusão, que cruza a variável o sucesso observado com o sucesso predito pelo modelo. Destas, destacam-se a PECC (percentagem de exemplos corretamente classificados), sensibilidade (percentagem de sucessos corretamente classificados) e especificidade (percentagem de insucessos corretamente classificados). Adicionalmente, analisaram-se a AUC e o gráfico de ganhos para uma melhor perceção da qualidade [20][24][25]. Todas estas métricas são avaliadas em novos casos, recorrendo-se, quer ao método de validação *hold-out* (com amostra de treino de 67% e a de teste com 33% dos projetos) e, também, à validação cruzada com 20 partições, já que a amostra é relativamente pequena [24].

A seleção do melhor modelo teve em consideração o modelo que apresentava maior PECC, mas garantindo que a sensibilidade e especificidade apresentavam valores próximos e superiores a 70%, isto é, garantindo-se que o modelo acerta em mais de três quartos dos casos. É de referir, ainda, que se optou por modelos mais simples quando os resultados estavam muito próximos.

#### IV. RESULTADOS

As análises efetuadas visam: i) analisar os indicadores de MR e a sua relação com o sucesso das candidaturas, ii) descrever o comportamento dos restantes preditores do sucesso, e iii) criar um modelo preditivo do sucesso das candidaturas com base em árvores de decisão para classificação.

##### A. MR e a sua relação com o sucesso dos projetos

A análise da MR revela que no ano da candidatura apenas 9,2% das empresas apresentam elevada probabilidade de manipular os seus resultados, sendo esse valor de 10,5% no ano anterior à candidatura. Adicionalmente, constata-se que apenas 9 empresas provavelmente manipularam os seus resultados nos dois anos e a grande maioria das empresas não apresentou fortes chances de manipular em nenhuma dos dois anos (81,9%).

Analisando a relação entre os indicadores de MR e o sucesso, constata-se que no ano anterior à candidatura não se identificam diferenças significativas, quer nas médias, quer nas distribuições dos indicadores de MR, entre os dois grupos de projetos (resultados não reportados). No entanto, no ano da candidatura já se identificam diferenças significativas nas médias dos indicadores DSRI, DEPI e SGAI ( $p \leq 0,05$ ) e nas distribuições dos indicadores SGI, DEPI e SGAI ( $p \leq 0,05$ ), levando a concluir que a MR no ano N pode, de facto, ter impacto no resultado final do projeto (Tabela II). Estes resultados confirmam estudos anteriores [3].

TABELA II. COMPARAÇÃO DOS INDICADORES DE MR ENTRE PROJETOS COM E SEM SUCESSO

Indicador MR	Sucesso (target)	Média	Desvio Padrão	Teste t Teste de Mann-Whitney
N_DSRI	Insucesso	1,182	0,841	$t(297,986) = 2,14$ $p = 0,033$
	Sucesso	1,047	0,476	$MW\_Z = -1,902$ $p = 0,057$
N_GMI	Insucesso	0,944	0,808	$t(552) = -0,233$ $p = 0,816$
	Sucesso	0,957	0,590	$MW\_Z = -0,216$ $p = 0,829$
N_AQI	Insucesso	0,006	0,067	$t(552) = 1,642$ $p = 0,101$
	Sucesso	-0,001	0,042	$MW\_Z = -1,859$ $p = 0,063$
N_SGI	Insucesso	1,116	0,659	$t(264,883) = -0,76$ $p = 0,448$
	Sucesso	1,152	0,293	$MW\_Z = -3,189$ $p = 0,001$
N_DEPI	Insucesso	1,101	0,552	$t(552) = -1,966$ $p = 0,050$
	Sucesso	1,215	0,718	$MW\_Z = -3,191$ $p = 0,001$
N_SGAI	Insucesso	1,132	0,516	$t(242,44) = 3,253$ $p = 0,001$
	Sucesso	1,013	0,174	$MW\_Z = -2,794$ $p = 0,005$
N_LVGI	Insucesso	1,030	0,216	$t(552) = -0,386$ $p = 0,699$
	Sucesso	1,043	0,468	$MW\_Z = -0,127$ $p = 0,899$
N_TATA	Insucesso	-0,034	0,180	$t(552) = 0,662$ $p = 0,508$
	Sucesso	-0,044	0,160	$MW\_Z = -1,377$ $p = 0,168$
M-Score N	Insucesso	-2,821	1,387	$t(360,108) = 0,941$ $p = 0,347$
	Sucesso	-2,925	1,043	$MW\_Z = -1,522$ $p = 0,128$

Relativamente aos outros preditores (Tabela III) destaca-se a duração média dos projetos de cerca de dois anos e o investimento médio de cerca de 1,5 milhões de euros, sendo que, em média, aproximadamente metade do investimento é apoiado pelos fundos europeus.

TABELA III. MEDIDAS DESCRITIVAS DAS VARIÁVEIS DA CANDIDATURA

Variáveis	Média	Desvio-padrão
Duração projeto (meses)	23,08	5,72
Investimento (x1000€)	1484,49	2163,15
Despesa elegível (x1000€)	1302,85	1988,58
Incentivo aprovado (x1000€)	746,04	1078,10
% Incentivo no investimento	50,90	14,83
% Incentivo reembolsável no incentivo	85,11	34,56
% Incentivo não reembolsável no incentivo	14,89	34,56
Mérito da candidatura	3,87	0,31

##### B. Resultados dos modelos preditivo do sucesso da candidatura

Para a obtenção dos modelos preditivos foram testadas diversas parametrizações para cada conjunto de preditores (dimensões de D1 a D4), apresentando-se apenas os melhores modelos para cada um dos conjuntos (Tabela IV). Em todos eles se recorreu a um ajustamento dos pesos de cada categoria do sucesso (um tipo de balanceamento dos dados de treino) para que o modelo apresentasse as métricas sensibilidade e especificidade relativamente próximas.

TABELA IV. RESULTADOS DOS MELHORES MODELOS EM NOVOS DADOS

Resultados modelos	Modelos			
	CART D1	CART D1 e D2	CHAID D1 a D3	CART D1 a D4
Parametrização	Bagging Balanceado	Bagging Balanceado	Bagging Balanceado	Bagging Balanceado
PECC (%)	63,43	65,71	78,86	85,14
Especificidade (%)	63,77	66,67	71,01	75,36
Sensibilidade (%)	63,21	65,09	83,96	91,51
AUC	0,663	0,702	0,818	0,892
Variáveis finais Top 3	N SGAI	Setor	Incentivo reembolsável / Incentivo	Incentivo não reembolsável / Incentivo
	N AQI	N TATA	Incentivo / Investimento	Incentivo reembolsável / Incentivo
	N DEPI	N M-Score	LN (Investimento)	Incentivo / Investimento

Relativamente ao modelo com apenas indicadores de MR conclui-se que este tem uma fraca capacidade preditiva (taxa de acerto em dados de teste de cerca de 63%) e que são os indicadores de MR do ano da candidatura que mais contribuem para a classificação do sucesso.

Num segundo modelo, já com as características das empresas candidatas, a qualidade melhora ligeiramente (taxa de acerto a rondar 66%) e o preditor mais importante passa a ser o setor de

atividade, mas mantêm-se como relativamente importantes os indicadores de MR do ano da candidatura.

Ao criar-se um modelo, incluindo como preditores as características da candidatura e dos projetos de investimento, ainda sem necessidade de intervenção do organismo intermédio, a qualidade do modelo aumenta, passando a ter uma taxa de acerto superior a 70%, sendo a especificidade a métrica que apresenta valor mais baixo (71,01%). Em relação aos preditores mais importantes verifica-se que são os relacionados com o valor do investimento ou com o peso dos incentivos os que se destacam.

Por fim, ao considerar-se, também o mérito do projeto a capacidade preditiva aumenta um pouco mais, mas o mérito não surge entre os preditores mais importantes. Neste modelo, o PECC é de 85,14% e a taxa de acerto dos insucessos é de 75,36%, bastante inferior aos 91,51% da taxa de acerto dos sucessos, mas ainda assim bastante boa. Os preditores mais importantes mantêm-se como no modelo anterior e o primeiro indicador de MR surge como o sétimo mais importante (N TATA).

Em suma, os resultados evidenciam que os melhores modelos são obtidos recorrendo ao *bagging*, já que se consegue uma maior capacidade de generalização. Importa, também, referir que os indicadores de MR são, de facto, importantes para prever o resultado do projeto, com informação disponível à data da candidatura, já que em todos os modelos há, pelo menos, um indicador de MR entre os mais importantes (*top 7*).

## V. CONCLUSÕES

Portugal vai receber a curto prazo fundos europeus, não só para a recuperação da economia devido à pandemia, mas também através do novo quadro comunitário de apoio 2021-2027. É, pois, urgente dotar os organismos decisores de ferramentas que ajudem à tomada de decisão de apoiar ou não os investimentos das empresas.

Os *insights* gerados pelos modelos obtidos, podem auxiliar os organismos intermédios na análise das candidaturas e, posteriormente, na verificação dos incentivos atribuídos. Adicionalmente, a evidência de que a MR tem, de certa forma, uma influência no sucesso do projeto, deve levar os decisores a terem especial atenção para este fenómeno e garantir que evitam aprovar candidaturas em que a MR tenha sido um meio para os empresários conseguirem ter os seus projetos apoiados. Um sistema de alertas pode ser fundamental para aumentar a eficiência e a eficácia do sistema de incentivos, traduzido numa atribuição mais justa e com impactos positivos para a economia portuguesa.

Noutra perspetiva, o estudo evidencia a capacidade preditiva das árvores de decisão para problemas de classificação, ainda sendo um estudo preliminar, mas, no futuro devem ser aplicados outros algoritmos de classificação, bem como a ponderação dos custos das decisões e alargar a amostra a outros sistemas de incentivos. A dimensão da amostra é a principal limitação e que pode ter comprometido o treino dos modelos de classificação.

## AGRADECIMENTOS

À FCT, pelo apoio no âmbito dos projetos estratégicos: UID/GES/00315/2020, UIDB/04466/2020 e UIDP/04466/2020.

## REFERÊNCIAS BIBLIOGRÁFICAS

- [1] L. Pires, “30 anos de Fundos Estruturais (1986-2015)”, *Relações Internacionais*, vol. R.I., nº 53, pp. 19-38, 2017.
- [2] M. Stec & M. Grzebyk, “The Implementation of the Strategy Europe 2020 Objectives in European Union Countries: The Concept Analysis and Statistical Evaluation”, *International Journal of Methodology - Quality and Quantity*, vol. 1, nº 53, pp. 119-133, 2018.
- [3] S. Fernandes & R. Laureano, “Manipulação de Resultados e Fraude nas Candidaturas a Fundos Europeus: Estudo em Empresas Portuguesas”, em *In Acta XX Congresso Internacional AECA*, 2019.
- [4] ECA - European Court of Auditors, “EU audit in brief”, Publications Office of the European Union, Brussels, 2017.
- [5] OLAF, “The OLAF report 2018”, Publications Office of the European Union, Brussels, 2018.
- [6] S. Callao & J. I. Jarne, “Have IFRS Affected Earnings Management in the European Union?”, *Accounting in Europe*, vol. 2, nº 7, pp. 159-189, 2010.
- [7] S. Davidson, C. Stickney & R. Weil, *Accounting: The Language of Business*, Sun Lakes, Arizona: Thomas Horton and Daughters, 1987.
- [8] P. Healy & J. Wahlen, “A Review of the Earnings Management Literature and its Implications for Standard Setting”, *Accounting Horizons*, vol. 4, nº 13, pp. 365-383, 1999.
- [9] M. Beneish, “Earnings management: A perspective”, *Managerial Finance*, vol. 12, nº 27, pp. 3-17, 2001.
- [10] C. Im & G. Nam, “Does Ethical Behavior of Management Influence Financial Reporting Quality?”, *Sustainability*, vol. 20, nº 11, pp. 5765-5781, 2019.
- [11] M. McNichols, “Research Design Issues in Earnings Management Studies”, *Journal of Accounting and Public Policy*, nº 19, pp. 313-345, 2000.
- [12] J. Jones, “Earnings Management During Import Relief Investigations”, *Journal of Accounting Research*, vol. (Autumn), nº 29, pp. 193-228, 1991.
- [13] P. Dechow, R. Sloan & A. Sweeney, “Detecting Earnings Management”, *The Accounting Review*, nº 70, pp. 193-225, 1995.
- [14] M. Beneish, “Detecting GAAP Violation: Implications for Assessing Earnings Management among Firms with Extreme Financial Performance”, *Journal of Accounting and Public Policy*, vol. 3, nº 16, pp. 271-309, 1997.
- [15] S. Kothari, A. Leone & C. Wasley, “Performance Matched Discretionary Accrual Measures”, *Journal of accounting and economics*, vol. 1, nº 39, pp. 163-197, 2005.
- [16] M. Beneish, “The Detection of Earnings Manipulation”, *Financial Analysts Journal*, vol. 5, nº 55, pp. 24-36, 1999.
- [17] M. Beneish, D. Nichols & C. Lee, “Earnings Manipulation and Expected Returns”, *Financial Analysts Journal*, vol. 2, nº 69, pp. 57-82, 2013.
- [18] M. Beneish, *Earnings Quality and Future Returns: The Relation between Accruals and the Probability of Earnings Manipulation*, Indiana: University, 2005.
- [19] M. Beneish & P. Vorst, “The Cost of Fraud Prediction Errors”, *Research Paper, nº. 2020-55*, Indiana: Kelley School of Business, 2020.
- [20] D. Delen, C. Kuzey & A. Uyar, “Measuring Firm Performance using Financial Ratios: A Decision Tree Approach”, *Expert Systems with Applications*, nº 40, pp. 3970-3983, 2013.
- [21] J. West & B. Bhattacharya, “Some Experimental Issues in Financial Fraud Mining”, *Procedia Computer Science*, nº 80, pp. 1734-1744, 2016.
- [22] L. Breiman, J. Friedman, R. Olshen & A. Sto, *Classification and Regression Trees*, Belmont, CA: Wadsworth, Ed., 1984.
- [23] G. V. Kass, “An Exploratory Technique for Investigating Large Quantities of Categorical Data”, *Applied Statistics*, vol. 29, nº2, pp.119-127, 1980.
- [24] D. Larose & C. Larose, *Data Mining and Predictive Analytics*, Wiley, 2015.
- [25] T. Wendler & S. Gröttrup, *Data Mining with SPSS Modeler: Theory, Exercises and Solutions*, Springer, 2016.