

**MANIPULAÇÃO DE RESULTADOS E FRAUDE NAS CANDATURAS A FUNDOS  
EUROPEUS: ESTUDO EM EMPRESAS PORTUGUESAS**

**Susana Fernandes \***

(Estudante de Doutoramento)

Instituto Universitário de Lisboa (ISCTE-IUL), ISTAR-IUL, Lisboa, Portugal Av. das  
Forças Armadas, 1649-026 Lisboa, Portugal

**Raul M. S. Laureano \***

(Professor Auxiliar)

Instituto Universitário de Lisboa (ISCTE-IUL), BRU-IUL, ISTAR-IUL, Lisboa, Portugal  
Av. das Forças Armadas, 1649-026 Lisboa, Portugal

Área científica: A) Informação financeira e normalização contabilística

Palavras-chave: Auditoria; Fraude; Manipulação de Resultados; Fundos Comunitários.

Keywords: Auditing; Fraud; Earnings Management; European Funds.

“Este trabalho é apoiado pela Fundação para a Ciência e a Tecnologia no âmbito dos projetos  
UID/GES/00315/2019 e UID/MULTI/04466/2019.”

\* Autor correspondente.

# MANIPULAÇÃO DE RESULTADOS E FRAUDE NAS CANDATURAS A FUNDOS EUROPEUS: ESTUDO EM EMPRESAS PORTUGUESAS

## Resumo

Portugal no período entre 2008 a 2014 concedeu 3 767 milhões de euros de incentivos financeiros às empresas portuguesas para alcançar a convergência europeia através do crescimento da economia. No entanto, muitas empresas não atingem o sucesso esperado com os investimentos financiados por este tipo de incentivos. Assim, importa identificar causas para este insucesso, definindo-se como objetivo deste estudo identificar empresas manipuladoras de resultados, num período que vai de dois anos antes da candidatura a dois anos após a candidatura.

Para o efeito, a partir das demonstrações financeiras de 2010 a 2017, de 442 empresas que tiveram os seus projetos de incentivos aprovados, aplica-se o modelo *M-Score de Beneish* para detetar práticas de manipulação de resultados nestas empresas. Os resultados permitem identificar práticas de contabilidade agressiva e/ou de propensão para a fraude em cerca de 30% das empresas. Em consequência, a principal contribuição deste estudo é ajudar as instituições portuguesas a serem eficientes na concessão de incentivos financeiros a empresas viáveis, sem evidência de manipulação de resultados e, assim, aumentar a eficácia dos fundos europeus na economia portuguesa.

## Abstract

The Portuguese State, for the period from 2008 to 2014, allocated 3 767 million euros of European funds to Portuguese companies, to achieve European convergence through economic growth. However, many companies do not achieve the expected success, thus it is important to identify the causes for this failure. Thereby, the aim of this study is to estimate the probability of fraud and earnings management for companies that received European financial incentives.

Thus, as of the financial statements from 2008 to 2017, of 442 companies that had their investment projects approved, it was used the Beneish M-Score model in detecting earnings management practices among these companies. The results allowed to identify aggressive accounting practices and/or propensity to commit fraud, in 30% of these companies. Consequently, the main contribution of this study is to help the Portuguese institutions to be efficient in their work, of providing financial support to viable companies without manipulation, thus increasing the effectiveness of European funds in the Portuguese economy.

## 1. INTRODUÇÃO

Os incentivos ao investimento empresarial tornaram-se num instrumento fundamental de políticas públicas de dinamização económica, não só em Portugal como nos restantes países da União Europeia (UE). E, após décadas de distribuição de fundos financeiros aos Estados-membros da UE, o objetivo de coesão económica e monetária ainda não foi alcançado, pois continuam a existir disparidades entre os Estados-membros da UE (Bachtler & Gorzelak, 2009; Wostner & Slander, 2009; Zaman & Geogescu, 2014; Cerqua & Pellegrini, 2016; Crescenzie & Giua, 2016). Por outro lado, tanto Becker *et al.* (2013, 2018) como Barone *et al.* (2016) evidenciaram que o impacto a curto prazo é positivo no desenvolvimento económico das regiões, mas que esse impacto positivo não perdura no tempo, ou seja, não se criam empresas viáveis e sustentáveis a longo prazo.

Em Portugal, por um lado, a execução dos fundos europeus é elevada, traduzida pela taxa de absorção (Comissão Europeia, 2016; Kersan-Škabić & Tijanić, 2017). Por outro, uma das orientações estruturantes do Quadro de Referência Estratégica Nacional (QREN) para 2007-2013 foi a maximização da viabilidade económica e a sustentabilidade financeira das empresas portuguesas (Observatório do QCA III, 2007). No entanto, Stec e Grzebyk (2018) levantam dúvidas sobre a eficácia da utilização dos fundos em Portugal, pois demonstram que estamos entre os países com um médio-baixo índice de implementação das estratégias da Europa 2020.

Uma possível razão para o comprometimento do sucesso prende-se com o facto de as candidaturas a estes programas de incentivos comunitários requererem o cumprimento de uma série de requisitos, tais como, assegurar 25% dos custos elegíveis com recursos próprios ou alheios e apresentar uma situação económica equilibrada, medida através dos rácios de autonomia financeira ou de uma situação líquida positiva (Decreto-Lei n.º 287/2007; Portaria n.º 1463/2007), e, nem sempre, as empresas conseguem-nos cumprir a tempo e dentro do período de candidaturas.

Por outro lado, após a atribuição dos incentivos, as empresas formalizam pedidos de pagamento, intercalares ou finais, e para que possam, efetivamente, beneficiar desses incentivos necessitam, igualmente, de cumprir uma série de requisitos, nomeadamente, a comprovação de despesas, garantir o grau de cumprimento dos contratos, e prestar

garantias bancárias (Decreto-Lei nº. 287/2007), e, muitas vezes, também não conseguem garantir todos os requisitos.

Assim, muitas empresas, quer para se candidatarem aos programas, quer para receberem os incentivos quando aprovados, podem ser tentadas a manipular resultados e/ou documentos, ou a cometer outras irregularidades (OLAF, 2015 ECA, 2017), por forma a estarem em conformidade com todos os requisitos dos programas e assim beneficiarem dos incentivos.

É neste contexto de desconfiança em relação ao comportamento das empresas que os organismos intermediários dos programas (e.g., AICEP, IAPMEI) têm a incumbência da indicação para a atribuição e verificação dos incentivos às empresas, cabendo-lhes a análise dos processos e a identificação de situações anómalas nesses processos, que podem ser de manipulação de contas e resultados e/ou fraude (OLAF, 2015; ECA, 2017).

É perante o problema que os Estados-membros enfrentam de, por um lado, melhorar a eficiência e eficácia dos programas comunitários e, por outro, de garantir que apenas as empresas cumpridoras acedem aos incentivos, que esta investigação pretende dar resposta à seguinte questão de investigação: Como é que as técnicas de análise de manipulação de resultados podem contribuir para melhorar a eficiência e a eficácia do processo de ajuda financeira às PME portuguesas?

A questão colocada traduz lacunas na literatura sobre incentivos comunitários. De facto, não se conhecem estudos em que se aplicam técnicas de análise de manipulação de resultados das empresas potencialmente candidatas e dos processos de candidatura quando estas formalizam as suas candidaturas. A análise e deteção de manipulação de resultados tem sido realizada, essencialmente, no âmbito da fiscalidade (Frank & Goyal, 2009; Shackelford *et al.*, 2011), de evidência de vitalidade junto de investidores e de efeitos da política (Roychowdhury, 2006).

A resposta à questão de investigação é operacionalizada através da análise de manipulação de resultados, em dados financeiros de empresas que obtiveram apoios financeiros em programas comunitários. Em particular, recorre-se ao modelo *M-Score de Beneish* (Beneish, 1997, 1999; Beneish *et al.*, 2013), que é o que tem mais popularidade (Ramirez-Orellana *et al.*, 2017) e que prevê a manipulação de resultados para uma empresa através de oito indicadores, permitindo identificar a prática de contabilidade agressiva e/ou propensão para cometer fraude (Beneish *et al.*, 2013).

Em particular, visa-se encontrar a manipulação de resultados efetuada "de propósito", pois esta dá uma indicação do errado desempenho da empresa. É de notar que a manipulação de resultados praticada pelo relato oportunístico de acréscimos não é necessariamente uma fraude, mas com o devido "incentivo" pode sê-lo (Talab *et al.*, 2017).

Deste modo, a resposta à questão de investigação leva à definição de três objetivos: i) identificação de manipulação de resultados nas demonstrações financeiras das empresas antes da candidatura; ii) identificação de manipulação de resultados nas demonstrações financeiras das empresas à data da candidatura; e iii) identificação de manipulação de resultados nas demonstrações financeiras das empresas após a candidatura.

Estes três objetivos, isto é, a deteção de manipulação de resultados nos três momentos é importante, pois permite prevenir não só a aprovação de candidaturas, mas também os pagamentos indevidos de incentivos financeiros, que provêm do orçamento da UE, comprometendo os objetivos europeus e mesmo os objetivos portugueses.

## **2. METODOLOGIA**

### **2.1. Amostra**

Entre 2008 a 2014, foram aprovados 3 648 projetos, submetidos por 2 138 empresas, com um valor de incentivo total aprovado de cerca de 3 382 milhões de euros. Existem empresas que obtiveram incentivos financeiros para vários projetos, representando 32% da totalidade das empresas com projetos aprovados e 63% do valor total de incentivos concedidos.

Uma vez que este estudo pretende analisar a fase anterior e posterior ao recebimento dos incentivos, foram só selecionadas as empresas que durante este quadro comunitário obtiveram assistência financeira a um só projeto e que apresentaram atividade nos três anos antes e posteriores à candidatura. Por outro lado, para cobrir todo o quadro comunitário (2008 a 2014), bem como para cumprir com os fins deste trabalho, é necessário obter dados financeiros a partir de 2005 e até 2017.

Os dados sobre os projetos aprovados foram recolhidos a partir do *website* do POFC e os dados financeiros obtidos através da base de dados AMADEUS (Data Base Bureau

Van Dijk Group). No entanto, só foi possível obter informação financeira, para estas empresas específicas, a partir de 2010.

Assim, devido às restrições ao acesso aos dados financeiros, a amostra é composta por 442 empresas portuguesas que obtiveram financiamento comunitário para apenas um projeto de investimento e que não apresentam valores anómalos (refletidos no M-Score de Beneish fora do intervalo de -6 a 6). As empresas repartem-se pelos dois anos, 2013 (206 empresas) e 2014 (236 empresas).

## 2.2. Dados

Atendendo aos objetivos e ao contexto do estudo, o modelo M-Score de Beneish (1999) é o mais adequado (Ramirez-Orellana *et al.*, 2017) para a realidade empresarial portuguesa e para os setores da indústria, comércio, serviços e turismo. De facto, Jones *et al.* (2007) demonstram que a utilização de técnicas de *accruals* específicos ao invés de técnicas de *accruals* agregados apresentam um maior poder explicativo, e vai dar indicações diretas para uma melhor regulamentação na contabilidade. E, Marinakis (2011), na apresentação de resultados do seu estudo, sugere uma relação sistemática entre a probabilidade de manipulação e os *accruals* específicos.

Adicionalmente, conforme sugerido por Beneish (1997, 1999), a análise do M-Score deve ser enquadrada no contexto das empresas estudadas, pelo que se torna fundamental conhecer as suas principais características. Deste modo, foram recolhidos dados de caracterização das empresas e da sua situação financeira (Tabela 1).

**Tabela 1: Variáveis demográficas e de situação financeiras das empresas**

Variável	Expressão de cálculo
<b>Demográficas</b>	
<i>Total assets</i>	
<i>Sales</i>	
<i>Sector de atividade</i>	
<i>Região</i>	
<i>Organismo intermédio</i>	
<i>Investimento elegível</i>	
<i>Incentivo contratualizado</i>	
<b>Liquidez / Endividamento</b>	
<i>Working capital to total assets</i>	$(Total\ current\ assets - Total\ current\ liabilities) / Total\ assets$
<i>Current ratio</i>	$Current\ assets / Current\ liabilities$
<i>Total debt to total assets</i>	$Total\ debts / Total\ assets$
<b><u>Rendibilidade / Crescimento</u></b>	

Return on assets

Net income / Total assets

Sales growth

$((\text{Current period net sales} - \text{Prior period net sales}) / \text{Prior period net sales})$

A aplicação do modelo de Beneish é conseguida através da combinação linear de oito variáveis financeiras, que analisadas isoladamente não têm grande significado (Beneish, 1999; Beneish *et al.*, 2013), mas que, em conjunto, vão ajudar a descobrir empresas que provavelmente manipulam os seus resultados. Como referido, este modelo foi desenvolvido para testar práticas de contabilidade agressiva e para a deteção da propensão de fraude (Ramirez-Orellana *et al.*, 2017).

As oito variáveis que contribuem para o M-Score de Beneish são apresentadas na Tabela 2. O M-Score é obtido através da seguinte fórmula:

$$M\text{-Score} = -4,840 + 0,920 \times DSRI + 0,528 \times GMI + 0,404 \times AQI + 0,892 \times SGI + 0,115 \times DEPI - 0,172 \times SGAI - 0,327 \times LVGI + 4,697 \times TATA$$

**Tabela 2: Variáveis constituintes do M-Score de Beneish**

Variável	Expressão de cálculo
<b>DSRI</b> Days Receivable Index	$(\text{Receivables } t / \text{Sales } t) / \text{Receivables } t-1 / \text{Sales } t-1)$
<b>GMI</b> Gross Margin Index	$[(\text{Sales } t-1 - (\text{COGS } t-1)) / \text{Sales } t-1] / [(\text{Sales } t - \text{COGS } t) / \text{Sales } t]$
<b>AQI</b> Asset Quality Index	$[1 - (\text{Current Assets } t + \text{PP\&E } t) / \text{Total Assets } t] / [1 - ((\text{Current Assets } t-1 + \text{PP\&E } t-1) / \text{Total Assets } t-1)]$
<b>SGI</b> Sales Growth Index	$\text{Sales } t / \text{Sales } t-1$
<b>DEPI</b> Depreciation Index	$(\text{Depreciation } t-1 / (\text{PP\&E } t-1 + \text{Depreciation } t-1)) / (\text{Depreciation } t / (\text{PP\&E } t + \text{Depreciation } t))$
<b>SGAI</b> SG&A Expense Index	$(\text{SG\&A } t / \text{Sales } t) / (\text{SG\&A } t-1 / \text{Sales } t-1)$
<b>LVGI</b> Leverage Index	$[(\text{Current Liabilities } t + \text{Total Long Term Debt } t) / \text{Total Assets } t] / [(\text{Current Liabilities } t-1 + \text{Total Long Term Debt } t-1) / \text{Total Assets } t-1]$
<b>TATA</b> Total Accruals to Total Assets	$(\Delta \text{ Working Capital} - \Delta \text{ cash} - \text{Depreciation } t) / \text{Total Assets } t$

Notas: t é o ano do projeto (candidatura) e t-k é o k ano anterior ao projeto e t+k é o k ano após o projeto  
COGS – Cost of goods sold  
PP&E – Property, Plant and Equipment is a non current and tangible asset  
SG&A – Selling, General & Administrative Expense

As variáveis deste modelo foram desenhadas para capturar as distorções dos dados financeiros constantes nos relatos financeiros e têm o seguinte significado (Beneish, 1999; Beneish *et al.*, 2013):

- DSRI – captura a distorção nos recebimentos e a sua consistência com as vendas. É um indicador de práticas de contabilidade agressiva;
- GMI – avalia se as margens brutas estão fragilizadas, dando indicação negativa sobre o futuro da empresa. É um indicador de fraude;
- AQI – mede as alterações e, assim, os riscos na qualidade do ativo do negócio. Poderá resultar numa capitalização excessiva e num diferimento de custos. É um indicador de fraude;
- SGI – apesar do crescimento não implicar manipulação, pode ser percebido como uma pressão para o crescimento e acabar por existir manipulação nas vendas e nos ganhos. É um indicador de fraude;
- DEPI – o crescimento deste indicador pode refletir um esforço para a redução das depreciações e, assim, aumentar os ganhos. É um indicador de práticas de contabilidade agressiva;
- SGAI – um crescimento desproporcional deste indicador pode ser visto como um sinal negativo. É um indicador de fraude;
- LVGI – um valor elevado deste indicador pode revelar um incentivo à gestão para manipular os resultados. É um indicador de fraude;
- TATA – captura quando os *accounting profits* não são suportados por *cash profits*. É um indicador de práticas de contabilidade agressiva.

Os valores de referência para identificar uma possível manipulação de resultados foram calculados por Beneish (1999) através do ponto *optimal cut-off* do custo do erro Tipo I – classificar como não manipuladora, quando de facto é uma manipuladora de resultados, e do custo do erro Tipo II – classificar como manipuladora de resultados, quando na realidade é uma não manipuladora. Estes valores de referência para o M-Score são apresentados na Tabela 3.

**Tabela 3: Valores de referência para o M-Score de Beneish**

Valor de referência	Custos relativos dos erros (Tipo I: Tipo II)
<i>M Score</i> > -1,49	(10:1)
<i>M Score</i> > -1,78	(20:1)
<i>M Score</i> > -1,89	(40+:1)



Para este estudo considera-se um M-Score  $> -1,89$  para classificar uma empresa como manipuladora de resultados.

### **2.3. Técnicas de análise de dados**

A análise dos dados tem um cariz quantitativo. Toda a análise dos dados foi realizada com o *IBM SPSS Statistics* (versão 25), recorrendo-se a técnicas de estatística descritiva uni e bivariada (Laureano e Botelho, 2017).

Previamente às análises foi avaliada a qualidade dos dados, quer em termos de não respostas, erros e *outliers*, tendo-se considerado como válida a amostra das 442 empresas.

Inicialmente calcula-se o M-Score para cinco anos, para o ano  $t$  da candidatura e para os dois anos anteriores ( $t-2$  e  $t-1$ ) e posteriores à candidatura ( $t+1$  e  $t+2$ ). Com base no M-Score obtido classificam-se as empresas em manipuladoras ou não manipuladoras e, recorrendo aos testes  $t$  e Mann-Whitney para duas amostras independentes, comparam-se as médias e as distribuições do M-Score e dos seus oito componentes entre os dois grupos de empresas (considera-se existir diferenças significativas quando a probabilidade de significância associada aos testes é igual ou inferior ao nível de significância definido de 0,05 (Laureano, 2013).

## **3. RESULTADOS**

Os resultados são apresentados atendendo aos objetivos, isto é, ao momento da análise do M-Score. No entanto, inicia-se esta secção com a caracterização da amostra.

### **3.1. Caracterização das empresas alvo do estudo**

As 442 empresas alvo do estudo caracterizam-se por ser essencialmente industriais (59,7%) e sediadas na região Norte (60,4%), tal como apresentado na Tabela 4. Relativamente à candidatura, cerca de metade das empresas submeteram a sua candidatura a programas geridos pelo IAPMEI (50,5%) ou AICEP (35,3%), sendo o montante total aprovado de aproximadamente de 170 milhões de euros.

Relativamente à situação financeira das empresas no ano da candidatura a fundos comunitários (Tabela 5) verifica-se uma elevada dispersão dos valores em torno da

média. De facto, verifica-se uma grande diversidade de empresas e dos projetos por si submetidos. Destaca-se que metade das empresas tem, no máximo, um ativo de 4,4 milhões de euros e de vendas de 4,2 milhões de euros. Já quanto ao incentivo obtido este varia entre 3,8 mil euros e 4,7 milhões de euros.

**Tabela 4: Distribuição das características demográficas das empresas**

<b>Característica</b>	<b>Empresas</b>	<b>%</b>
Organismo intermédio		
AdI	27	6,1
AICEP	156	35,3
IAPMEI	223	50,5
PO Centro	23	5,2
POFC	1	0,2
TP	12	2,7
Sector de atividade		
Comércio	69	15,6
Construção	22	5,0
Indústria	264	59,7
Serviços	63	14,3
Transportes	9	2,0
Turismo	15	3,4
Região		
Norte	267	60,4
Centro	119	26,9
Lisboa	4	0,9
Alentejo	21	4,8
Algarve	6	1,4
Multi regiões	25	5,7

Nota: N=442 empresas.

Relativamente aos rácios financeiros verifica-se que o ativo corrente líquido tem um peso, em média, de 21% do total do ativo (*working capital to total assets* = 0,21). Já no que se refere à liquidez geral (*current ratio*), que avalia a aptidão das empresas para fazer face aos seus compromissos de curto prazo, verifica-se que metade das empresas apresenta, no máximo, uma liquidez de 1,44, sendo um valor aceitável (Fernandes *et al.*, 2012), apesar de carecer de um estudo aprofundado, utilizando padrões comparativos sectoriais, pois a média de 1,98 e a dispersão dos valores em seu torno ser elevada. Noutra perspetiva, o peso do endividamento, traduzido no indicador *total debt to total assets*, que traduz a dependência das empresas face ao capital alheio, é,

em média, de 0,62 e, em mediana, de 0,66. Assim, sabendo-se que um dos requisitos para a aprovação de projetos é a demonstração de uma situação financeira equilibrada, isto é, uma situação em que a autonomia financeira não seja inferior a 20%, constata-se que, quer em média (38%), quer em mediana (34%), a autonomia financeira das empresas está conforme a determinação legislativa.

**Tabela 5: Distribuição das características financeiras das empresas no ano da candidatura**

Variáveis	Média	Desvio-padrão	Mínimo	Mediana	Máximo
<b>Demográficas</b>					
<i>Total assets (x 1000 €)</i>	11037,7	26984,2	46,3	4352,8	304389,8
<i>Sales (x 1000 €)</i>	10104,4	21215,6	9,0	4157,7	226531,9
Investimento elegível (x 1000 €)	660,8	1345,0	5,0	211,8	10389,6
Incentivo contratualizado (x 1000 €)	359,0	705,1	3,8	111,3	4693,2
<b>Liquidez / Endividamento</b>					
<i>Working capital to total assets</i>	0,21	0,24	-0,74	0,22	0,89
<i>Current ratio</i>	1,98	2,41	0,17	1,44	29,55
<i>Total debt to total assets</i>	0,62	0,20	0,02	0,66	0,98
<b>Rendibilidade / Crescimento</b>					
<i>Return on assets (%)</i>	0,03	0,07	-0,49	0,02	0,34
<i>Sales growth (%)</i>	23,54	61,32	-78,74	8,54	449,74

Nota: N=442 empresas.

Por fim, relativamente à rendibilidade e crescimento verifica-se que o crescimento das vendas (*sales growth*) é elevado (média de 23,5%), mas variando entre -78,7% e 449,7%. Mas, por outro lado, a rendibilidade do ativo (*return on assets*) é muito baixa, sendo em média de 0,03% e em mediana é de 0,02%. É de notar que estes valores podem indicar uma gestão pouco eficiente por parte destas empresas.

### 3.2. M-Score de Beneish e identificação de empresas manipuladoras de resultados

O cálculo do M-Score para as 442 empresas, em cada um dos cinco anos em análise, isto é, desde dois anos anteriores à candidatura efetuada no ano t até dois anos após a candidatura, leva a concluir pela existência de evidências de manipulação de resultados. De facto, a Tabela 6 mostra que a partir do percentil 75, nos 5 anos considerados, os valores de M-Score apontam para a manipulação de resultados, ao apresentarem valores superiores a -1,89.

**Tabela 6: M-Score no ano da candidatura e nos dois anos antes e após**

M-Score de Beneish	Média	Desvio-padrão	Mínimo	Percentil 25	Mediana	Percentil 75	Máximo
M-Score t-2	-2,19	1,37	-5,89	-2,92	-2,23	-1,57	4,49
M-Score t-1	-2,13	1,07	-5,77	-2,71	-2,21	-1,69	3,61
M-Score	-1,96	1,19	-5,96	-2,51	-2,08	-1,49	5,70
M Score t+1	-2,09	1,00	-5,62	-2,65	-2,16	-1,65	2,37
M Score t+2	-2,03	1,19	-5,58	-2,62	-2,14	-1,62	4,21

Nota: N=442 empresas.

Atendendo ao valor limiar do M-Score, a partir do qual as empresas apresentam evidências de manipulação de resultados, classificam-se as empresas em manipuladoras (M-Score > -1,89) e em não manipuladoras (caso contrário). A Tabela 7 evidencia que em todos os cinco anos a maioria das empresas não são manipuladoras, variando o seu peso entre 63,8%, no segundo ano anterior à candidatura, e 68,3% no ano anterior à candidatura. No entanto, analisando os dois anos antes e os dois anos após conclui-se que a maioria das apresenta evidência de manipulação antes (56,1%) e após (58,1%).

**Tabela 7: Empresas manipuladoras de resultados em cada um dos cinco anos**

Manipulação em momento referente à candidatura		Empresas	%
Manipuladora ano t-2	Não	282	63,8
	Sim	160	36,2
Manipuladora ano t-1	Não	302	68,3
	Sim	140	31,7
Manipuladora anos antes	Não	194	43,9
	Sim	248	56,1
Manipuladora ano t	Não	275	62,2
	Sim	167	37,8
Manipuladora ano t+1	Não	293	66,3
	Sim	149	33,7
Manipuladora ano t+2	Não	286	64,7
	Sim	156	35,3
Manipuladora anos após	Não	185	41,9
	Sim	257	58,1

Nota: N=442 empresas.

### 3.3. M-Score e suas variáveis nos anos anteriores à candidatura

As Tabelas 8 e 9 apresentam a comparação dos valores do M-Score e das suas oito variáveis entre as empresas não manipuladoras e as manipuladoras, para os anos que antecedem a candidatura. Adicionalmente, apresentam os resultados dos testes t e de Mann-Whitney que permitem identificar as variáveis em que as suas médias e as suas distribuições são significativamente diferentes entre os dois tipos de empresas.

**Tabela 8: M-Score e suas variáveis por tipo de empresa no ano dois anterior à candidatura**

Indicador de Beneish	Tipo de empresa	Média	Desvio-padrão	Mediana	Teste t Teste de Mann-Whitney
DSRI	Não manipuladora	0,97	0,35	0,95	t(186,6)=-4,8; p<0,001 MW=16698; p<0,001
	Manipuladora	1,33	0,91	1,08	
	Total	1,10	0,64	0,98	
GMI	Não manipuladora	1,01	0,22	1,00	t(440)= 0,4; p=0,711 MW=21956,5; p=0,640
	Manipuladora	1,00	0,26	1,00	
	Total	1,01	0,24	1,00	
AQI	Não manipuladora	0,99	0,06	1,00	t(440)=-1,8; p=0,066 MW=19952; p=0,043
	Manipuladora	1,00	0,06	1,00	
	Total	1,00	0,06	1,00	
SGI	Não manipuladora	0,86	0,41	0,78	t(189,5)=-7,5; p<0,001 MW=12673; p<0,001
	Manipuladora	1,48	1,01	1,16	
	Total	1,08	0,75	0,91	
DEPI	Não manipuladora	1,03	0,38	0,98	t(186,9)=-1,1; p=0,280 MW=20467,5; p=0,105
	Manipuladora	1,11	0,98	0,93	
	Total	1,06	0,67	0,97	
SGAI	Não manipuladora	1,04	0,25	1,00	t(440)=0,3; p=0,783 MW=21471; p=0,399
	Manipuladora	1,03	0,32	0,99	
	Total	1,03	0,28	1,00	
LVGI	Não manipuladora	1,00	0,16	0,98	t(234,6)=2,5; p=0,012 MW=18980; p=0,006
	Manipuladora	0,94	0,25	0,95	
	Total	0,98	0,20	0,98	
TATA	Não manipuladora	-0,14	0,16	-0,10	t(440)=-14,6; p<0,001 MW=5622; p<0,001
	Manipuladora	0,10	0,18	0,09	
	Total	-0,05	0,21	-0,04	
<b>M-Score</b>	<b>Não manipuladora</b>	<b>-2,93</b>	<b>0,84</b>	<b>-2,72</b>	<b>t(440)=-21,9; p&lt;0,001</b> <b>MW=0; p&lt;0,001</b>
	<b>Manipuladora</b>	<b>-0,87</b>	<b>1,11</b>	<b>-1,26</b>	
	<b>Total</b>	<b>-2,19</b>	<b>1,37</b>	<b>-2,23</b>	

**Tabela 9: M-Score e suas variáveis por tipo de empresa no ano um anterior à candidatura**

Indicador de Beneish	Tipo de empresa	Média	Desvio-padrão	Mediana	Teste t Teste de Mann-Whitney
DSRI	Não manipuladora	0,92	0,29	0,91	t(150,6)=-6,8; p<0,001
	Manipuladora	1,48	0,95	1,17	
	Total	1,10	0,64	0,97	MW=11359,0; p<0,001
GMI	Não manipuladora	1,00	0,15	0,99	t(153,9)=-1,2; p=0,227
	Manipuladora	1,05	0,43	1,00	
	Total	1,02	0,27	1,00	MW=18988; p=0,085
AQI	Não manipuladora	0,99	0,05	1,00	t(440)=-3,1; p=0,002
	Manipuladora	1,01	0,06	1,00	
	Total	1,00	0,05	1,00	MW=16620; p<0,001
SGI	Não manipuladora	1,03	0,33	1,01	t(157,1)=-4,3; p<0,001
	Manipuladora	1,37	0,89	1,15	
	Total	1,14	0,59	1,04	MW=15264; p<0,001
DEPI	Não manipuladora	1,11	0,54	1,00	t(440)=-0,1; p=0,896
	Manipuladora	1,12	0,52	0,96	
	Total	1,11	0,54	0,99	MW=19753; p=0,267
SGAI	Não manipuladora	1,01	0,16	1,00	t(167,6)=-0,8; p=0,424
	Manipuladora	1,03	0,34	0,99	
	Total	1,01	0,23	0,99	MW=20472; p=0,593
LVGI	Não manipuladora	1,00	0,17	0,98	t(440)=-0,959; p=0,338
	Manipuladora	1,02	0,26	1,00	
	Total	1,01	0,20	0,98	MW=19739; p=0,262
TATA	Não manipuladora	-0,10	0,12	-0,07	t(202,1)=-11,0; p<0,001
	Manipuladora	0,07	0,17	0,05	
	Total	-0,05	0,16	-0,04	MW=6413; p<0,001
<b>M-Score</b>	<b>Não manipuladora</b>	<b>-2,66</b>	<b>0,65</b>	<b>-2,51</b>	<b>t(207,2)=-19,7; p&lt;0,001</b>
	<b>Manipuladora</b>	<b>-0,99</b>	<b>0,90</b>	<b>-1,31</b>	
	<b>Total</b>	<b>-2,13</b>	<b>1,07</b>	<b>-2,21</b>	<b>MW=0; p&lt;0,001</b>

A nível global confirma-se que o M-Score é significativamente inferior ( $p < 0,001$ ) nas empresas não manipuladoras do que nas manipuladoras, nos dois anos em análise. No entanto, no que respeita às oito variáveis, verificam-se diferenças significativas nas médias e/ou as distribuições do DSRI, AQI, TATA e SGI entre os dois tipos de empresas, para os dois anos antes da candidatura, e do LVGI, apenas no ano dois anterior à candidatura. Deste modo, apenas três variáveis (GMI, DEPI e SGAI) não permitem

diferenciar as empresas não manipuladoras das manipuladoras no período anterior à candidatura.

### 3.4. M-Score e suas variáveis no ano da candidatura

No ano da candidatura (Tabela 10) encontram-se diferenças significativas no M-Score e nas suas variáveis DSRI, AQI, SGI e TATA entre as empresas não manipuladoras e as manipuladoras. Assim, apenas quatro variáveis (menos uma do que nos períodos anteriores à candidatura) permitem diferenciar os dois tipos de empresas.

**Tabela 10: M-Score e suas variáveis por tipo de empresa no ano da candidatura**

Indicador de Beneish	Tipo de empresa	Média	Desvio-padrão	Mediana	Teste t
					Teste de Mann-Whitney
DSRI	Não manipuladora	0,95	0,27	0,97	t(176,254)=-4,597; p<0,001 MW=15623,0; p<0,001
	Manipuladora	1,39	1,21	1,14	
	Total	1,11	0,80	1,01	
GMI	Não manipuladora	0,98	0,23	1,00	t(440)=-1,291; p=0,197 MW=20777,5; p=0,093
	Manipuladora	1,01	0,21	1,00	
	Total	0,99	0,22	1,00	
AQI	Não manipuladora	0,99	0,06	1,00	t(440)=-3,232; p=0,001 MW=19152,0; p=0,003
	Manipuladora	1,01	0,12	1,00	
	Total	1,00	0,08	1,00	
SGI	Não manipuladora	1,04	0,27	1,03	t(187,454)=-7,847; p<0,001 MW=12362,0; p<0,001
	Manipuladora	1,56	0,84	1,24	
	Total	1,24	0,61	1,09	
DEPI	Não manipuladora	1,23	0,75	1,00	t(232,311)=-1,307; p=0,192 MW=21813,0; p=0,377
	Manipuladora	1,37	1,31	1,04	
	Total	1,28	1,00	1,01	
SGAI	Não manipuladora	1,08	0,26	1,04	t(280,465)=0,544; p=0,587 MW=20703,0; p=0,083
	Manipuladora	1,06	0,35	1,01	
	Total	1,07	0,30	1,03	
LVGI	Não manipuladora	1,04	0,23	1,00	t(440)=1,818; p=0,070 MW=21207,0; p=0,178
	Manipuladora	1,00	0,21	0,99	
	Total	1,02	0,22	1,00	
TATA	Não manipuladora	-0,10	0,13	-0,06	t(440)=-12,877; p<0,001 MW=7830,0; p<0,001
	Manipuladora	0,07	0,14	0,05	
	Total	-0,04	0,15	-0,03	
<b>M-Score</b>	<b>Não manipuladora</b>	<b>-2,60</b>	<b>0,65</b>	<b>-2,38</b>	<b>t(232,169)=-17,717; p&lt;0,001</b> <b>MW=0,0; p&lt;0,001</b>
	<b>Manipuladora</b>	<b>-0,90</b>	<b>1,13</b>	<b>-1,26</b>	
	<b>Total</b>	<b>-1,96</b>	<b>1,19</b>	<b>-2,08</b>	

Nota: N=442 empresas.

### 3.5. M-Score e suas variáveis nos anos seguintes à candidatura

Nos anos após a candidatura confirma-se a existência de diferenças significativas no M-Score entre empresas não manipuladoras e manipuladoras ( $p < 0,001$ ), para os dois anos (Tabelas 11 e 12). No que respeita às oito variáveis, verificam-se diferenças significativas nas médias e/ou as distribuições do DSRI, TATA e SGI entre os dois tipos de empresas, nos dois anos seguintes à candidatura. O AQI e o GMI só nos dois anos após a candidatura. Deste modo, apenas três variáveis (DEPI, SGAI e LVGI) não permitem diferenciar as empresas não manipuladoras das manipuladoras no período após a candidatura.

**Tabela 11: M-Score e suas variáveis por tipo de empresa no ano um após a candidatura**

Indicador de Beneish	Tipo de empresa	Média	Desvio-padrão	Mediana	Teste t Teste de Mann-Whitney
DSRI	Não manipuladora	0,93	0,26	0,94	$t(166,6) = -6,7$ ; $p < 0,001$
	Manipuladora	1,35	0,75	1,19	
	Total	1,07	0,52	1,00	$MW = 11157$ ; $p < 0,001$
GMI	Não manipuladora	1,01	0,16	1,00	$t(440) = -0,4$ ; $p = 0,668$
	Manipuladora	1,02	0,22	1,00	
	Total	1,01	0,19	1,00	$MW = 21246$ ; $p = 0,646$
AQI	Não manipuladora	0,97	0,18	0,99	$t(440) = -1,7$ ; $p < 0,088$
	Manipuladora	1,00	0,28	1,00	
	Total	0,98	0,22	0,99	$MW = 20909$ ; $p = 0,469$
SGI	Não manipuladora	1,03	0,31	1,04	$t(193,2) = -5,0$ ; $p < 0,001$
	Manipuladora	1,28	0,57	1,12	
	Total	1,11	0,43	1,05	$MW = 16663$ ; $p < 0,001$
DEPI	Não manipuladora	1,16	0,81	0,98	$t(440) = 1,4$ ; $p = 0,161$
	Manipuladora	1,06	0,53	0,96	
	Total	1,12	0,73	0,97	$MW = 19692$ ; $p = 0,092$
SGAI	Não manipuladora	1,03	0,17	1,02	$t(222,1) = 0,4$ ; $p = 0,696$
	Manipuladora	1,02	0,24	1,00	
	Total	1,02	0,19	1,01	$MW = 20571$ ; $p = 0,322$
LVGI	Não manipuladora	1,00	0,18	0,98	$t(440) = 1,7$ ; $p = 0,087$
	Manipuladora	0,97	0,25	0,98	
	Total	0,99	0,20	0,98	$MW = 19071$ ; $p = 0,030$
TATA	Não manipuladora	-0,10	0,12	-0,07	$t(247,5) = -13,5$ ; $p < 0,001$
	Manipuladora	0,10	0,15	0,07	
	Total	-0,03	0,16	-0,03	$MW = 4957$ ; $p < 0,001$
<b>M-Score</b>	<b>Não manipuladora</b>	<b>-2,60</b>	<b>0,62</b>	<b>-2,46</b>	<b><math>t(238,0) = -20,4</math>; <math>p &lt; 0,001</math></b>
	<b>Manipuladora</b>	<b>-1,07</b>	<b>0,81</b>	<b>-1,23</b>	
	<b>Total</b>	<b>-2,09</b>	<b>1,00</b>	<b>-2,16</b>	<b><math>MW = 0</math>; <math>p &lt; 0,001</math></b>



**Tabela 12: M-Score e suas variáveis por tipo de empresa no ano dois após a candidatura**

Indicador de Beneish	Tipo de empresa	Média	Desvio-padrão	Mediana	Teste t Teste de Mann-Whitney
DSRI	Não manipuladora	0,93	0,29	0,93	t(173,1)=-6,6; p<0,001
	Manipuladora	1,42	0,91	1,13	
	Total	1,10	0,63	0,98	MW=11806; p<0,001
GMI	Não manipuladora	0,98	0,16	1,00	t(211,0)=-2,3; p=0,022
	Manipuladora	1,04	0,27	1,00	
	Total	1,00	0,21	1,00	MW=21291; p=0,428
AQI	Não manipuladora	0,99	0,06	1,00	t(440)=-3,8; p<0,001
	Manipuladora	1,02	0,14	1,00	
	Total	1,00	0,10	1,00	MW=16872; p<0,001
SGI	Não manipuladora	1,05	0,30	1,05	t(184,9)=-5,6; p<0,001
	Manipuladora	1,39	0,72	1,17	
	Total	1,17	0,51	1,07	MW=15798; p<0,001
DEPI	Não manipuladora	1,09	0,79	0,99	t(440)=0,8; p=0,426
	Manipuladora	1,04	0,33	0,98	
	Total	1,07	0,67	0,98	MW=21923; p=0,764
SGAI	Não manipuladora	0,98	0,15	0,98	t(214,2)=0,2; p=0,880
	Manipuladora	0,98	0,26	0,96	
	Total	0,98	0,20	0,98	MW=20647; p=0,196
LVGI	Não manipuladora	0,98	0,14	0,98	t(440)=-0,1; p=0,935
	Manipuladora	0,99	0,29	0,97	
	Total	0,98	0,20	0,98	MW=20863; p=0,260
TATA	Não manipuladora	-0,10	0,12	-0,07	t(440)=-14,0; p<0,001
	Manipuladora	0,10	0,17	0,06	
	Total	-0,03	0,17	-0,03	MW=3207; p<0,001
<b>M-Score</b>	<b>Não manipuladora</b>	<b>-2,64</b>	<b>0,67</b>	<b>-2,47</b>	t(214,8)=-17,4; p<0,001
	<b>Manipuladora</b>	<b>-0,91</b>	<b>1,13</b>	<b>-1,26</b>	
	<b>Total</b>	<b>-2,03</b>	<b>1,19</b>	<b>-2,14</b>	MW=0; p<0,001

#### 4. DISCUSSÃO E CONCLUSÃO

A atribuição de incentivos financeiros às empresas, provenientes da UE visa, em última instância, contribuir para o desenvolvimento económico e social dos países. Ao longo dos últimos 40 anos e após vários quadros comunitários, a perceção e os estudos realizados demonstram que os incentivos têm sido deficientemente aproveitados. Para

aumentar a probabilidade de os incentivos serem devidamente atribuídos é necessário ter em atenção a viabilidade das empresas, identificando as empresas que manipulam resultados para efeitos de candidatura e acesso a incentivos financeiros, evitando-se, assim, que estas acedam aos incentivos.

Deste modo, os organismos intermédios têm todo o interesse em identificar as empresas que manipulam resultados, isto é, que apresentam indícios de contabilidade agressiva e/ou de fraude. Para este fim, recorre-se ao modelo M-score de *Beneish* para identificar as empresas que manipulam os resultados antes, à data e/ou após a candidatura.

Os resultados obtidos com a aplicação do modelo nos três períodos temporais demonstram que é possível, não só identificar as empresas manipuladoras de resultados, como também demonstrar como o fazem antes, à data e após a candidatura.

De facto, encontrou-se evidência para afirmar que nos cinco anos analisados houve práticas de contabilidade agressiva expressa através das variáveis DSRI e TATA. Em particular, é preocupante o DSRI das empresas manipuladoras ao longo dos cinco anos, pois apresentam um sinal de potencial inflação da receita. O estudo de Jones *et al.* (2007) corrobora este resultado ao concluir que as contas de inventários e de recebimentos estavam envolvidas na manipulação de resultados em 35% e 61% das empresas, respetivamente.

Por outro lado, a variável SGI, um dos indicadores de fraude, está presente antes, no ano e depois da candidatura, apresentando valores que significam um crescimento rápido das vendas, para as empresas manipuladoras, entre 28% a 56% versus o não crescimento ou o máximo de 5% para as empresas não manipuladoras. Também este resultado encontra suporte em Marinakis (2011), que no seu estudo evidenciou a ligação entre a manipulação de resultados e as altas taxas de crescimento das vendas.

Adicionalmente, tendo-se em consideração que, na análise inicial às empresas, o rácio de rentabilidade ROA (*return on assets*), não apresentava, em média, valor superior a 2,3%, então estes resultados poderão indiciar mais do que a ineficiência das empresas. Esta ineficiência poderá tornar as empresas inviáveis e os incentivos concedidos desperdiçados.

Por último, existem três variáveis constituintes do M-Score, AQI, o LVGI e o GMI que são indicadores de fraude, mas não são estatisticamente significativas em todos os anos considerados. Assim, deverá existir uma especial atenção à qualidade do ativo do

negócio, nomeadamente à sua capitalização excessiva e/ou diferimento de custos. Por outro lado, por via do GMI, existe a indicação da fragilização das margens brutas, dando deste modo, um sinal negativo sobre o futuro das empresas que receberam incentivos financeiros. Estes casos poderão ser evitados ou mitigados se existir uma análise à manipulação de resultados por parte dos organismos competentes.

Desta forma, este estudo evidencia que indicadores de manipulação de resultados, nomeadamente o M-Score de *Beneish*, devem ser analisados pelos organismos intervenientes nos processos de atribuição e verificação de incentivos financeiros às empresas, pois empresas que manipulam resultados podem estar a usufruir de incentivos em detrimento de outras que poderiam ter um retorno maior desse investimento. Assim, existe ganhos de eficiência através da optimização dos processos, ao direccionar as verificações para as empresas que evidenciam manipulação de resultados e especificamente, para a análise de rubricas das demonstrações financeiras relativas às variáveis, componentes do M-Score de *Beneish*, que são estatisticamente significativas.

Para trabalho futuro existe a necessidade de avaliar financeiramente estas empresas, e comparar com os valores do respetivo sector/ano para que se consiga despistar eventuais anomalias. Assim, será possível identificar perfis de empresas com propensão para uma contabilidade agressiva e acima de tudo para a fraude. Será também importante estudar a relação entre a manipulação de resultados e o grau de concretização dos contratos de incentivos.

Em suma, esta investigação contribui para a aplicação de boas práticas nas instituições públicas portuguesas, ao permitir uma identificação atempada de casos de contabilidade agressiva ou mesmo de fraude. Só assim se conseguirá um maior cumprimento com o contratualizado, reduzir as rescisões dos contratos de incentivos, reduzir o risco de pagamentos indevidos, e direccionar os incentivos financeiros para empresas viáveis, que não tenham as contas manipuladas e potencialmente ajudam o crescimento da economia. De outra forma, esta investigação gera conhecimento que permitirá obter maior eficiência, otimizando os recursos através da melhoria contínua dos processos, e, conseqüentemente, aumentar a eficácia, baseando os processos de decisão num conhecimento profundo da realidade e tecnicamente sustentado nos dados, para a alocação dos incentivos financeiros a empresas que demonstrem que não têm práticas de manipulação de resultados.

## REFERÊNCIAS BIBLIOGRÁFICAS

Bachtler, J., & Gorzelak, G. (2009). Reforming EU cohesion policy: A reappraisal of the performance of the structural funds. Routledge, ERPC Publications.

Barone, G., David, F., & Blasio, G. (2016). Boulevard of broken dreams. The end of EU funding (1997: Abruzzi, Italy). *Regional Science and Urban Economics*, 60, pp. 31-38.

Becker, S.H., Egger, P., & Going, M. (2013). Going NUTS: The effect of EU structural funds on regional performance. *American Economic Journal: Economic Policy*, 5(4), pp. 29-77.

Becker, S.H., Egger, P., & Going, M. (2018). Effects of EU regional policy: 1989-2013. *Regional Science and Urban Economics*, 69, pp. 143-152.

Beneish, M.D. (1997). Detecting GAAP violation: Implications for assessing earnings management among firms with extreme financial performance. *Journal of Accounting and Public Policy*, 16(3), pp. 271-309.

Beneish, M.D. (1999). The detection of earnings manipulation. *Financial Analysts Journal*, 55(5), pp. 24-36.

Beneish, M.D., Lee, C.M.C., & Nichols, D.C. (2013). Earnings manipulation and expected returns. *Financial Analysts Journal*, 69(2), pp. 57-82.

Cerqua, A., & Pellegrini, G. (2016). Measuring the impact of Structural and Cohesion Funds using regression discontinuity design in EU27 in the period 1994-2011. Final Technical Report. Directorate-General for Regional and Urban Policy Publications Office of the European Union.

Comissão Europeia (2016). Relatório da Comissão Europeia, InfoRegio, Bruxelas, 2016

Crescenzi, R., & Giua, M. (2016). Different approaches to the analysis of the EU cohesion policy: Leveraging complementarities for evidence-based policy learning. In: Berkowitz, P., Bachtler, J., Muravska, T. & Hardy, S., (eds.) *EU Cohesion Policy: reassessing performance and direction. Regions and Cities*. Routledge, Abingdon, UK, pp. 21-32.

Decreto-Lei nº. 287/2007, Diário da República, 1.ª série de 17 de agosto de 2007. Aprova o enquadramento nacional dos sistemas de incentivos ao investimento das empresas, que define as condições e as regras a observar pelos sistemas de incentivos ao investimento nas empresas aplicáveis no território do continente durante o período de 2007 a 2013.

ECA (2017). EU audit in brief- 2016. Publications Office of the European Union, European Court of Auditors.

Fernandes, C., Peguinho, C., Vieira, E., & Neiva, J. (2012). *Análise Financeira Teoria e Prática – Aplicação no âmbito do SNC*, 1ª edição, Lisboa: Edições Sílabo

Frank, M.Z., & Goyal, V.K. (2009). Capital structure decisions around the world: Which factors are reliably important?. *Financial Management*, 38(1), pp.1–37.

Jones, K., Krishnan, G., & Melendrez, K. (2007). Do models of discretionary accruals detect actual cases of fraudulent and restated earnings? An empirical analysis. *Contemporary Accounting Research*, 25, pp 499-531.

Kersan-Škabić, I. & Tijanić, L. (2017). Regional absorption capacity of EU funds. *Economic Research-Ekonomska Istraživanja*, 30(1), pp. 1191-1208.

Laureano, R. (2013). *Testes de Hipóteses com o SPSS: o meu manual de consulta rápida*, 2ª edição, Lisboa: Edições Sílabo.

Laureano, R., & Botelho, M. (2017). *IBM SPSS Statistics: o meu manual de consulta rápida*, 3ª edição, Lisboa: Edições Sílabo.

Marinakis, P. (2011). An investigation of earnings management and earnings manipulation in the UK. PhD thesis, University of Nottingham. <http://eprints.nottingham.ac.uk/12874/1/555391.pdf>

Observatório do QCA III (2007). Quadro de referência estratégico nacional - Portugal 2007-2013, p. 11.

OLAF (2015). The role of Member States' auditors in fraud prevention and detection. European Union. Directorate D — Policy, European Anti-Fraud Office.

Portaria nº 1463/2007 1.a série de 15 de novembro de 2007. Aprova o Regulamento do Sistema de Incentivos à Qualificação e Internacionalização de PME (SI Qualificação de PME).

Ramírez-Orellana, A., Martínez-Romeroa, M., & Marino-Garrido, T. (2017). Measuring fraud and earnings management by a case of study: Evidence from an international family. *Business European Journal of Family Business*, 7, pp. 41-53.

Resolução do Conselho de Ministros n.º 25/2006 - Diário da República n.º 50/2006, Série I-B de 10 de março de 2006. Aprova as orientações fundamentais para elaboração do Quadro de Referência Estratégico Nacional e programas operacionais para o período de 2007-2013.

Roychowdhury, S. (2006). Earnings management through real activities manipulation. *Journal of Accounting and Economics*, 42, pp. 335-370.

Shackelford, D.A., Slemrod, J., & Sallee, J.M. (2011). Financial reporting, tax, and real decisions: toward a unifying framework. *International - Tax and Public Finance*, 18, pp. 461-494.

Stec, M. & Grzebyk, M. (2018). The Implementation of the Strategy Europe 2020 Objectives in European Union Countries: The Concept Analysis and Statistical Evaluation. *International Journal of Methodology - Quality & Quantity*, 52(1), pp. 119-133.

Szilágyi, K., & Ször, B. (2009). The growth effects of EU transfers: An empirical investigation. Department of Economics, National Bank of Hungary.

Talab, H., Flayyih, H., & Ali, S. (2017). Role of Beneish M-score model in detecting of earnings management practices: Empirical study in listed banks of Iraqi stock exchange. *International Journal of Applied Business and Economic Research*, 15(23, Part 2), pp. 287-302.

Wostner, P., & Slander, S. (2009). The effectiveness of EU cohesion policy revisited: Are EU funds really additional?. *European Policies Research Centre* (69).

Zaman, G., & Georgescu, G. (2014). Structural fund, absorption: A new challenge for Romania?. *Romanian Journal of Economic Forecasting*, 1, pp. 136-154.