

COMBINAÇÃO DE DIFERENTES *PROXIES* PARA AFERIR A QUALIDADE DA INFORMAÇÃO FINANCEIRA

Daniel Filipe Figueiredo de Sá, a33368@alunos.ipb.pt, Instituto Politécnico de Bragança
Jorge Manuel Afonso Alves, jorge@ipb.pt, UNIAG, Instituto Politécnico de Bragança,
OBEGEF

RESUMO: Assumindo que a Qualidade da Informação Financeira (QIF) configura um conceito multidimensional que depende de diversos fatores, definiu-se como objetivo primordial da investigação a combinação de diferentes *proxies* identificadas na literatura para aferir a QIF. Para tal, recorreu-se à Análise de Equações Estruturais (AEE) como técnica estatística que visa, através da operacionalização de um Modelo de Equações Estruturais (MEE), perceber as relações causais entre as diferentes variáveis observáveis e a variável latente QIF. Os resultados demonstram, conforme esperado, que os *Accruals* Discricionários (DAC), o valor anormal das vendas, o valor anormal do custo das vendas e a não existência de uma relação de sinal idêntico entre Fluxos de Caixa Operacionais (FCO) e os *Earnings Before Interest, Taxes, Depreciation and Amortization* (EBITDA) contribuem negativamente para a QIF. Assim, com a combinação de diferentes *proxies* é possível encontrar uma medida de quantificação da QIF que inclua diferentes fatores e que seja mais robusta.

PALAVRAS-CHAVE: Qualidade da informação financeira, Análise de equações estruturais, Modelo de equações estruturais.

ABSTRACT: Understanding that the Earnings Quality (EQ) configures a multidimensional concept that depends from several factors, it was defined as the primary objective of the investigation the combination of different proxies identified in the literature to measure the EQ. For this, were used Structural Equation Modeling Analysis (SEMA) as a statistical technique that aims, through the operationalization of a Structural Equation Model (SEM), to understand the causal relations between the different observable variables and the latent variable EQ. The results demonstrate, as expected, that Discretionary Accruals (DAC), abnormal sales value, abnormal cost of sales and the absence of an identical signal relationship between Operating Cash Flows (CFO) and Earnings Before Interest, Taxes, Depreciation and Amortization (EBITDA) contribute negatively to EQ. Thus, by combining different proxies, it is possible to find a EQ quantification measure that includes different factors and that is more robust.

KEYWORDS: Earnings quality, Structural equation modeling analysis, Structural equation model.

1. INTRODUÇÃO

A problemática da QIF tem sido amplamente discutida no meio científico ligado à Contabilidade, já que, como é natural nas ciências sociais, a medição de uma variável que é, à partida, inobservável levanta sempre alguma celeuma. Deste modo, não se tratando de uma variável diretamente observável, constitui um conceito multidimensional que deverá ser medido por diversas outras variáveis. Tal como referem Dechow, Ge e Schrand (2010), a qualidade dos resultados é inerente à relevância, quantidade e capacidade que os mesmos possam ter para a tomada de decisão e medição do desempenho de uma entidade. No entanto, de forma a hiperbolizar o desempenho económico, financeiro e organizacional, algumas entidades recorrem a mecanismos que acabam por prejudicar a QIF.

Por norma, a QIF é quantificada através de uma só variável, por exemplo pelos DAC (Chen, Hribar, & Melessa, 2018). Todavia, compreendendo a QIF como sendo um conceito multidimensional, implica que a mesma dependa de mais do que um fator. Deste modo, importa identificar e conjugar diferentes fatores e medir as suas implicações na QIF das entidades. Assim, a pertinência deste estudo surge do aproveitamento

da lacuna existente (quantificação da QIF apenas através de uma única *proxy*, como acontece frequentemente com a utilização dos DAC) e passa por quantificar a QIF recorrendo a uma combinação de diferentes *proxies* baseadas nos fatores acima referidos. Das diferentes *proxies* que são utilizadas na literatura para aferir a QIF, selecionaram-se os DAC (Jones, 1991), o valor anormal das vendas (Roychowdhury, 2006), o valor anormal dos custos das vendas (Roychowdhury, 2006) e a relação existente entre resultados e FCO (Banimahd & Aliabadi, 2013) como fatores que influenciam a QIF.

Para a execução prática da combinação de fatores acima proposta, foram utilizados dados económico-financeiros de empresas portuguesas. Após a identificação das *proxies* que operacionalizam os fatores explanados, recorreu-se à AEE como técnica de modelação tendo em vista testar a validade do modelo teórico e das relações causais entre as variáveis manifestas e latente (Marôco, 2014). Com recurso a esta técnica, foi possível, não só quantificar a QIF por empresa e por ano, como também avaliar a qualidade do ajustamento global e individual do modelo de análise e perceber a existência de diferenças estatisticamente significativas da QIF por setor e por atividade empresarial.

A presente investigação encontra-se dividida em quatro secções. A primeira secção fornece a base teórica para a execução do estudo e compreende os subpontos do conceito e medição da QIF. A segunda secção explica a metodologia e consequentes técnicas estatísticas utilizadas na persecução do trabalho, incidindo maioritariamente sobre a explicação do método de AEE. Na terceira secção, efetua-se uma caracterização da amostra recorrendo à análise descritiva dos dados, avaliam-se os pressupostos inerentes à AEE, a qualidade do ajustamento do modelo e apresentam-se as estimativas estandardizadas dos fatores que servem de suporte à validação das hipóteses de investigação. Por fim, apresentam-se as principais conclusões, limitações e sugestões para trabalhos futuros.

2. REVISÃO DE LITERATURA

2.1. CONCEITO DE QUALIDADE DA INFORMAÇÃO FINANCEIRA

A QIF é, indiscutivelmente, um dos temas contabilísticos mais discutidos pela comunidade científica, como são disso prova os vários estudos realizados sobre o tema (Carmo, 2013; Dechow, Ge, & Schrand, 2010; Gutiérrez & Rodríguez, 2017). Tal como referem Gutiérrez e Rodríguez (2017), uma das características da QIF que mais desperta a atenção da comunidade científica é o facto de esta ser inobservável a olho nu, o que faz com que se tentem desenvolver diversas *proxies*, baseados nas várias propriedades contabilísticas da Informação financeira (IF), como método de medição desta. Como nenhuma destas *proxies* demonstra uma capacidade preditiva superior às demais, a QIF é considerada como um conceito multidimensional (Gutiérrez & Rodríguez, 2017).

No sentido mais lato, a IF representa toda a informação, quer de natureza quantitativa quer qualitativa, que é formalmente divulgada pelas empresas. Num sentido mais restrito, a IF acaba por se confundir com a informação contabilística, predominantemente de natureza quantitativa, preparada segundo os pressupostos e características definidas e divulgada através das demonstrações financeiras. Dentro da IF divulgada, o resultado contabilístico é aquele que maior conteúdo informativo possui (Carmo, 2013).

Há três características a reter sobre a definição de qualidade dos resultados. Primeiro, a qualidade dos resultados está condicionada à relevância que a informação tem para a tomada de decisão. Assim, segundo esta definição, o termo “qualidade dos resultados” *per se* não tem qualquer significado. Segundo, a qualidade dos resultados depende da quantidade de informação relevante que estes conseguem dar sobre o desempenho financeiro da empresa. Terceiro, a qualidade dos resultados depende conjuntamente da relevância da informação que estes possuem sobre o desempenho da empresa, e ainda da capacidade que o sistema contabilístico tem para medir e transmitir esse desempenho (Dechow et al., 2010).

Não se tratando de um facto rapidamente detetável, a QIF configura, tal como referenciado nos parágrafos acima, um conceito multidimensional. A única forma possível de medi-la é recorrendo à IF divulgada pelas empresas. No entanto, esta informação nem sempre traduz uma imagem verdadeira e apropriada da real situação económico-financeira de uma empresa, já que não raras vezes essa informação é adulterada. Deste modo, importa referir quais as propriedades da IF que serão estudadas de forma a obter uma maior base conceptual para o estudo empírico. De entre as muitas características dos resultados, Banimahd e Aliabadi (2013), Gutiérrez e Rodríguez (2017) e Roychowdhury (2006) destacam a manipulação de resultados e a

relação entre os resultados e os FCO como alguns daqueles que apresentam um maior valor explicativo sobre a quantificação da QIF.

2.2. MEDIÇÃO DA QUALIDADE DA INFORMAÇÃO FINANCEIRA

De acordo com o referido acima, de seguida faz-se uma breve descrição e análise às *proxies* vulgarmente utilizadas para medir a manipulação de resultados e a relação entre os resultados e os FCO.

2.2.1. MANIPULAÇÃO DE RESULTADOS

2.2.1.1. MANIPULAÇÃO DISCRICIONÁRIA

Uma das características que define a QIF é a capacidade que o sistema contabilístico tem para medir e transmitir o desempenho financeiro da empresa. Como tal, um dos aspetos mais influenciadores da IF é a flexibilidade das normas contabilísticas. As normas contabilísticas tornam-se flexíveis sempre que proporcionem ao gestor mais do que uma opção de contabilização ou quando deixam ao seu livre arbítrio a escolha do tratamento contabilístico adequado (Carmo, 2013).

O estudo da manipulação de resultados é uma das questões mais aprofundadas dentro das temáticas associadas à contabilidade, sendo que o que se tenta entender são as causas e as consequências desta prática. Em geral, a manipulação de resultados ocorre através do uso subtil das informações financeiras por parte dos gestores como meio para obter vantagens para si ou para a empresa. Estas opções do gestor podem levar a que as demonstrações financeiras não transmitam uma imagem verdadeira e apropriada da situação económico-financeira da empresa, levando a que a opinião dos *stakeholders* seja deturpada (Carmo, 2013; Gutiérrez & Rodríguez, 2017).

Uma das limitações mais recorrentes apontadas a estas pesquisas é o facto de as técnicas existentes para medir a manipulação de resultados não terem muita força e serem pouco precisas (Dechow, Hutton, Kim, & Sloan, 2012). O procedimento típico para a deteção e medição da manipulação de resultados é baseado numa regressão linear em duas fases, isto é, primeiro estimam-se os DAC como a componente residual de uma regressão linear e posteriormente usa-se essa componente residual como variável dependente numa segunda regressão linear como forma de testar as hipóteses de investigação (Chen et al., 2018). Segundo os mesmos autores, a grande parte dos estudos, na segunda fase da regressão, omitem as variáveis independentes utilizadas na primeira fase, levando a que os resultados finais obtidos sejam tendenciosos.

Pese embora apresente algumas deficiências, como o facto de se incorrer várias vezes na omissão de variáveis e na pouca capacidade dos modelos para isolar os DAC, a *proxy* mais comum para detetar e medir a manipulação de resultados, baseia-se em isolar essa componente discricionária dos *accruals*. No sentido de limitar as deficiências apontadas a este tipo de *proxy*, foram desenvolvidos diversos modelos que permitissem separar os *accruals* nas suas componentes normal e anormal. Deste modo, regra geral os *accruals* normais resultam da atividade normal da empresa e são obtidos através dos valores ajustados dos modelos. Quanto aos *accruals* anormais, segundo Carmo (2013), são dados pelos resíduos dos modelos e podem apresentar sinal positivo ou negativo, sendo medidos em valor absoluto, estes indicam que quanto maior for o seu valor maior será a discricionariedade e, conseqüente, menor será a qualidade dos resultados. Na literatura são utilizados diversos modelos para estimar os DAC (*e.g.*, Jones, 199; Dechow, Sloan & Sweeney, 1995; Kothari, Leone & Wasley, 2005; Dechow & Dichev, 2002; Francis, LaFond, Olsson & Schipper, 2005; Dechow et al., 2012; Larson, Sloan & Giedt, 2018).

O modelo de Jones (1991) tem em consideração a variação do volume de negócios e o nível dos ativos fixos tangíveis como variáveis explicativas dos *accruals*. A primeira variável tem como objetivo apurar o efeito que as alterações na atividade normal da empresa originam nos *accruals* totais. Quanto à variável dos ativos fixos tangíveis, esta controla o efeito das depreciações nos *accruals* totais, considerando que estas também representam *accruals* normais, isto é, o seu reconhecimento e mensuração não é afetado pela discricionariedade do gestor. Por fim, os resíduos da fórmula representam a componente discricionária dos *accruals* (Carmo, 2013; Jones, 1991).

O modelo de Jones (1991) foi sofrendo algumas modificações ao longo dos anos, sendo a primeira das quais a modificação proposta por Dechow, Sloan, e Sweeney (1995). Esta modificação consistiu em retirar à

variação das vendas a variação das contas a receber. Com isto, a intenção dos autores foi retirar o efeito das vendas a crédito nos *accruals*, visto que para eles, não são raras as vezes em que estas vendas se traduzem em práticas de manipulação de resultados. Tratando-se deste tipo de situações, as vendas a crédito representam *accruals* anormais, não devendo estar refletidas na variação do volume de negócios (Carmo, 2013; Dechow et al., 1995).

Outra das modificações efetuadas ao modelo de Jones (1991), foi desenvolvida por Kothari, Leone e Wasley, (2005). A fórmula proposta por estes autores é em tudo semelhante à proposta por Jones (1991) e por Dechow et al. (1995). No entanto, os autores acrescentam uma nova variável, o Rácio de Rendibilidade dos Ativos (ROA). Esta alteração visa controlar o nível de desempenho de uma empresa na determinação dos *accruals* anormais (Carmo, 2013; Kothari et al., 2005).

O modelo desenvolvido por Dechow e Dichev (2002) que se foca na relação que é estabelecida ao longo do tempo entre os fluxos de caixa e os *accruals*. Segundo os autores deste modelo, os *accruals* normais de curto prazo resultam da soma dos fluxos de caixa passados, presentes e futuros. Quanto aos DAC, estes são obtidos através dos resíduos do modelo e o seu desvio padrão é usado pelos autores como *proxy* para medir a QIF, sendo que estes consideram que quanto maior for essa variabilidade, menor é a qualidade dos resultados (Carmo, 2013; Dechow & Dichev, 2002).

Ainda no decorrer do mesmo ano em que Dechow e Dichev (2002) apresentaram o seu modelo de medição dos *accruals*, McNichols (2002) apresentou o seu trabalho onde discute e apresenta algumas modificações ao modelo destes autores. Ora estas modificações traduzem-se na introdução no modelo de Dechow e Dichev (2002) das variáveis explicativas do modelo de Jones (1991). Com isto, o autor pretendeu excluir dos DAC os *accruals* associados à variação da atividade normal da empresa e as depreciações (Carmo, 2013). Segundo McNichols (2002), ligar o estudo de Dechow e Dichev (2002) com o de Jones (1991) tem o potencial de fortalecer ambos os estudos e tornar mais preciso a capacidade do modelo medir os DAC e consequentemente a QIF.

Tal como a maioria dos modelos, o modelo de Francis, LaFond, Olsson, e Schipper (2005) baseia-se em distinguir as duas componentes dos *accruals*, os normais e os anormais. A primeira componente é explicada, neste modelo, por variáveis como a dimensão da empresa, os fluxos de caixa operacionais e o volume de negócios, tendo estes fatores em comum, o facto de estarem dependentes de fatores externos à empresa e não diretamente ligados ao órgão de gestão. Quanto à segunda componente, a discricionária, esta é consequência das escolhas contabilísticas dos gestores que por razões oportunistas tomam decisões que acabam por esconder a imagem verdadeira e apropriada das demonstrações financeiras (Carmo, 2013; Francis et al., 2005).

Sendo já várias as formas de medir os *accruals*, Dechow et al. (2012) propõem uma nova abordagem para a deteção da manipulação de resultados que visa determinar mais adequadamente a componente anormal dos *accruals* (Carmo, 2013). De acordo com esta nova abordagem de Dechow et al. (2012), os *accruals* originados num período serão revertidos nos períodos seguintes sendo que desta forma, e se o investigador tiver antecedentes que provem em que período serão revertidos, os *accruals*, este modelo trará uma maior robustez científica e superará algumas das lacunas dos anteriores módulos. Assim, os autores propõem a incorporação de variáveis dicotómicas que identificam quer o período em que os *accruals* surgem, quer o período em que estes serão revertidos.

Mais recentemente, Larson, Sloan e Giedt (2018) desenvolveram uma nova teoria que visa determinar os *accruals* tendo por base três fatores: crescimento do negócio, diferenças temporárias entre o facto económico e os *cash-flows* a ele associados e, finalmente, a incorporação assimétrica de ganhos e perdas nos resultados. Como, segundo os autores deste modelo, estas três variáveis possuem um grande valor explicativo em relação à componente normal dos *accruals*, foram desenvolvidas *proxies* individuais relacionadas com os três fatores que visam explicar a componente normal dos *accruals*, sendo que os resíduos do modelo representam os DAC. O resultado final desta nova teoria traduz-se numa compilação de três *proxies* num único modelo com capacidade explicativa dos três fatores acima referenciados.

2.2.1.2. MANIPULAÇÃO REAL

Como já anteriormente referenciado, o estudo da manipulação de resultados é uma das temáticas que levanta mais celeuma na comunidade científica na área de investigação quantitativa em contabilidade financeira, que tenta compreender o “como, quando e porquê” de esta acontecer. Como forma de responder a estas

perguntas, foram, e continuam a ser desenvolvidos diversos modelos que, através dos DAC, visam não só perceber se determinada IF foi manipulada como também a quantificação dessa manipulação. No entanto, existe um *gap* teórico na investigação da manipulação, e este prende-se com a escassez de estudos (*e.g.*, Cohen, Dey, & Lys, 2008; Enomoto, Kimura, & Yamaguchi, 2015; Ge & Kim, 2014; Li, Tseng, & Chen, 2016; Mellado-Cid, Jory, & Ngo, 2017) sobre a utilização de práticas reais de manipulação de resultados.

Tal como referenciado nos parágrafos acima, a manipulação de resultados ocorre através do uso subtil da IF por parte dos gestores como meio para obter vantagens para si ou para a empresa. No entanto, esta manipulação de resultados pode ocorrer de três formas: como já dito no subponto anterior, através da flexibilidade das normas contabilísticas; através da utilização de práticas reais de manipulação de resultados; e, por fim, através da manipulação fraudulenta da IF e das transações comerciais (Alves & Moreira, 2014). Importa assim distinguir que práticas de manipulação real de resultados são mais comumente utilizadas, e o porquê de o serem, pelos gestores e perceber se estas práticas podem configurar fraude económica e/ou branqueamento de capitais.

A utilização de práticas reais de manipulação de resultados pode ser definida como uma saída da prática de atividades operacionais normais, motivada pelos gestores pretenderem levar os *stakeholders* a acreditar que determinadas metas foram atingidas no decurso normal das operações (Roychowdhury, 2006). Roychowdhury (2006) refere ainda que na maior parte das vezes estas práticas não contribuem necessariamente para criar valor na empresa, sendo apenas um meio de os gestores atingirem os objetivos que lhes permitam obter vantagens para si próprios. Um bom exemplo disso é a prática de descontos radicais, estes podem ter subjacentes a si uma meta de atingir determinado volume de negócios que consequentemente trará para o gestor uma contrapartida financeira (Roychowdhury, 2006).

A médio e longo prazo a utilização recorrente destas práticas de adulteração de resultados acabam por destruir valor na empresa. Utilizando o exemplo acima, a utilização de descontos radicais tendo em vista o aumento do volume de negócios, com alguma frequência leva a uma diminuição na margem bruta e pode levar os consumidores a esperarem por mais descontos no futuro. Ora isto leva a que no futuro a margem bruta se continue a reduzir o que origina um efeito negativo nos FCO futuros (Roychowdhury, 2006). De forma a detetar a prática de atividades de manipulação real de resultados, são, por norma, estudadas as variáveis que mais influência têm nos resultados das empresas, as vendas e custo das mercadorias vendidas (CMV) cujas *proxies* se encontram detalhadas em modelos utilizados por Roychowdhury (2006).

O modelo apresentado para estimar o valor das vendas anormais por Roychowdhury (2006) trata-se de uma *proxy* comumente utilizada nas investigações sobre o tema (*e.g.*, Alves & Moreira, 2014; Cohen et al., 2008; Ge & Kim, 2014) e assenta no pressuposto dos FCO normais serem aqueles que uma empresa deveria registar caso não existisse manipulação das vendas. Já os FCO anormais, *proxy* da manipulação real das vendas, são dados pelos resíduos do modelo ou pela diferença entre os FCO atuais e os normais (Alves & Moreira, 2014). Deste modo, quanto mais longe de zero estiverem os resíduos do modelo mais se verifica a existência de manipulação real das vendas e, consequentemente, menor será a QIF.

Quanto ao modelo utilizado para estimar o CMV anormais por Roychowdhury (2006), trata-se de um modelo usado para identificar a existência de CMV anormais face ao valor de vendas faturado. Em determinadas situações, os gestores são levados a considerar um CMV superior ao que seria normal face ao volume de vendas faturado o que origina uma inflação dos custos e consequentemente uma diminuição clara da QIF (Alves & Moreira, 2014).

2.2.2. FLUXOS DE CAIXA E RESULTADOS

Os fluxos de caixa consistem em influxos (recebimentos, entradas) e efluxos (pagamentos, saídas) de caixa e seus equivalentes refletidos numa peça das demonstrações financeiras a Demonstração de Fluxos de Caixa (DFC). O principal objetivo da DFC é informar sobre os recebimentos e os pagamentos de uma empresa ocorridos num determinado período. Para tal, a DFC classifica os fluxos de caixa reportados em fluxos de caixa de atividades operacionais, de investimento e de financiamento (Caiado & Gil, 2014; Rodrigues, 2015).

Quanto às atividades operacionais, estas são as principais atividades geradoras de réditos da entidade bem como quaisquer outras que não sejam de investimento ou financiamento. As atividades de investimento dizem respeito à aquisição e alienação de ativos de longo prazo e devem ser suportadas a médio e longo prazo pelas atividades operacionais, pese embora, no imediato poderem ser também suportadas pelas atividades de financiamento. Estas últimas, são as atividades que têm como consequência alterações na dimensão e composição do capital próprio e dos financiamentos obtidos (Oliveira, 2017; Rodrigues, 2015).

A DFC é uma das principais fontes de análise da situação económico-financeira da empresa, visto que permite uma análise dos níveis de liquidez, viabilidade e flexibilidade financeira, capacidade de gerar e utilizar caixa e seus equivalente e ainda na definição estratégica dos negócios das entidades no que concerne ao investimento e financiamento (Oliveira, 2017). Para além disso, a importância da DFC reside no facto de, na teoria, esta não estar sujeita à denominada “contabilidade criativa”, ou seja, não é possível manipular as entradas e saídas de dinheiro, ao contrário dos resultados, que podem ser adulterados por depreciações insuficientes/excessivas, provisões sobreavaliadas ou subavaliadas, resultados reconhecidos antecipadamente ou diferidos para períodos futuros (Rodrigues, 2015).

Tanto os fluxos de caixa como os Resultados são duas das propriedades da IF mais utilizadas para medir o desempenho das empresas. Analistas financeiros, investidores, credores, *Chief Executive Officer* (CEO) e os demais utilizadores da IF costumam usar os resultados e os FCO como *proxy* para prever o desempenho futuro das empresas (Banimahd & Aliabadi, 2013). Mas para além desse carácter preditivo, a correlação entre FCO e os Resultados pode também assumir um carácter explicativo da QIF, uma vez que são vários os estudos (e.g., Banimahd & Aliabadi, 2013; Lopes, 2017; Pinto, 2017) que referem que os FCO e os Resultados refletem o mesmo desempenho económico, isto é, quando um é positivo o outro também e vice-versa. Sempre que tal não ocorra, poder-se-á estar perante atos de adulteração da IF que originam uma diminuição da QIF.

2. METODOLOGIA DE INVESTIGAÇÃO

Esta secção encontra-se dividida em 6 subpontos que no seu conjunto servem para explicar quais os procedimentos usados no decorrer da investigação tendo em vista a obtenção dos resultados. No primeiro subponto é descrito o objetivo do estudo bem como a base teórica que suporta as hipóteses de investigação. De seguida, escarpelizam-se os passos seguidos desde a recolha dos dados até à amostra final do estudo. Nos terceiro e quarto subpontos são explicados os métodos de análise estatística usados que suportam os resultados obtidos. Por fim, nos dois últimos subpontos são desenvolvidos os pressupostos do modelo de análise bem como os métodos que são utilizados para avaliar a qualidade do ajustamento do mesmo.

2.1. OBJETIVO DO ESTUDO E HIPÓTESES DE INVESTIGAÇÃO

Como explanado na revisão da literatura, uma das maiores falhas apontadas à medição da QIF é o facto de nenhuma *proxy* demonstrar uma capacidade preditiva superior às demais, o que torna a QIF num conceito multidimensional. Deste modo, apresentadas que estão as diferentes propriedades da IF, importa definir quais as *proxies* a escolher para integrar no modelo que define a QIF e consequentemente os principais objetivos e hipóteses de investigação do presente artigo. Como tal, com base no explanado na revisão da literatura e nos diversos trabalhos de investigação apresentados, define-se como propriedades estudadas a manipulação discricionária de resultados, a manipulação real de resultados e a relação entre FCO e resultados. Estes últimos são representados pelo EBITDA. As propriedades da IF, as *proxies* associadas e alguns dos estudos que as utilizaram encontram-se esquematizadas na Tabela 1.

Tabela 1: Definição das *proxies*

Propriedade da IF	<i>Proxy</i>	Autores
Manipulação de resultados (DAC)	$AT_{i,t} = \alpha + \beta_1 \Delta VN_{i,t} + \beta_2 AFT_{i,t} + \varepsilon_{i,t}$	Jones (1991)
Manipulação real das vendas e do CMV	$\frac{FCO_t}{A_{t-1}} = \alpha_1 + \alpha_2 \frac{1}{A_{t-1}} + \alpha_3 \frac{VEPS_t}{A_{t-1}} + \alpha_4 \frac{\Delta VEPS_t}{A_{t-1}} \varepsilon_t$ $\frac{CMV_t}{A_{t-1}} = \alpha_1 + \alpha_2 \frac{1}{A_{t-1}} + \alpha_3 \frac{VEPS_t}{A_{t-1}} + \varepsilon_t$	(e.g., Alves & Moreira, 2014; Cohen et al., 2008; Ge & Kim, 2014; Roychowdhury, 2006)
Relação entre FCO e EBITDA	Variável <i>dummy</i> que assume o valor 0 se a relação for positiva e 1 se for negativa	(e.g., Banimahd & Aliabadi, 2013; Lopes, 2017; Pinto, 2017)

Fonte: Elaboração própria

Recorda-se que o objetivo primordial da investigação é a combinação das diferentes *proxies* identificadas na Tabela 1 para aferir com maior segurança a QIF. Para tal, utiliza-se um MEE onde se introduzem as variáveis predefinidas tendo em vista a definição da variável latente, a QIF. Para além do objetivo principal do estudo, tem-se como meta secundária perceber a capacidade preditiva que, isoladamente, cada uma das *proxies* possui. Isto é, tentar-se perceber qual a propriedade da IF com maior capacidade explicativa da QIF. Dito isto, as hipóteses de investigação que norteiam o presente estudo são as seguintes:

H₁: Os DAC influenciam negativamente a QIF.

H₂: O valor anormal das vendas influencia negativamente a QIF.

H₃: O valor anormal do custo das mercadorias vendidas influencia negativamente a QIF.

H₄: Se os FCO e o EBITDA apresentarem o mesmo sinal, ou seja, ambos positivos ou ambos negativos, isso influencia positivamente a QIF.

Quanto à *H₁*, esta pretende estudar se o impacto dos DAC na QIF é negativo, isto é, quanto mais as empresas recorrem a este tipo de mecanismo de manipulação discricionária de resultados menor será a QIF. Com a *H₂* e *H₃*, pretende-se provar que o constante recurso à manipulação real de resultados, quer através das vendas quer através dos custos diretamente associados a estas, influencia negativamente a QIF, na medida em que estes mecanismos prejudicam a perceção da real margem bruta que a atividade operacional da empresa gera e, conseqüentemente, prejudicando os resultados. Por fim, relativamente à *H₄*, tenciona-se provar que as entidades cuja relação entre FCO e EBITDA for positiva (as duas variáveis apresentam o mesmo sinal, isto é, ou ambos positivos ou ambos negativos) apresentam uma melhor QIF. De seguida, é apresentado o processo desde a seleção inicial da base de dados até à amostra final de empresas.

2.2. BASE DE DADOS E AMOSTRA

Para a prossecução dos objetivos definidos anteriormente torna-se necessário extrair e analisar diversos dados económico-financeiros de empresas. Para tal, foi utilizada a base de dados do Sistema de Análise de Balanços Ibéricos (SABI), fornecida pela empresa Bureau van Dijk e cujo acesso foi possível através da Unidade de Investigação Aplicada em Gestão (UNIAG). Esta é uma ferramenta de pesquisa e tratamento de dados que fornece diversos indicadores económico-financeiros de empresas ibéricas. Como a investigação incide sobre empresas portuguesas, com esta ferramenta é possível obter dados históricos de mais de 700.000 entidades, dando assim origem a uma vasta população.

Deste modo, inicialmente foram selecionadas todas as sociedades disponíveis para o período de 2010 a 2017 cujo total de ativo fosse superior a um milhão de euros. Esta primeira seleção originou uma base de dados composta por 65.696 empresas a que correspondem 525.568 observações. Com uma tão vasta base de dados, foi necessário efetuar uma depuração da mesma. Após a eliminação de dados omissos para variáveis necessárias ao estudo, resultou um total de observações de 126.237. Em seguida foram eliminadas todas as observações cujo número por indústria e por ano era inferior a 15. Posteriormente, converteram-se as variáveis DAC, Volume de Negócios Anormal (VNA) e Custo das Mercadorias Vendidas Anormal (CMVA) em valores absolutos de modo a que se possa simplificar a leitura dos resultados. Foram, de seguida, eliminadas as observações com valores mais extremos nas variáveis em estudo como forma de eliminar possíveis *outliers*. Por fim, para que os resultados se tornassem mais homogéneos e mais simples de ler, eliminaram-se todos os valores absolutos superiores a 1 das variáveis DAC, VNA e CMVA.

2.3. TRATAMENTO DOS DADOS

Para a execução da presente investigação e de forma a poder combinar diferentes *proxies* para aferir a QIF, foi usada a AEE. Esta define-se como uma técnica de modelação utilizada para testar a validade de modelos teóricos que definem relações causais entre variáveis (Marôco, 2014). Em termos mais simplistas, a AEE resulta da combinação das técnicas clássicas de Análise Fatorial e de Regressão Linear (Marôco, 2014). A AEE é amplamente utilizada nas ciências sociais e da saúde, visto que, não raras vezes, o investigador se depara com variáveis que não são diretamente observáveis, apenas os seus efeitos ou manifestações o são (Marôco, 2014). De acordo com Marôco (2014), a AEE permite ainda testar o ajustamento global dos modelos, bem como a significância individual de parâmetros numa generalização teórica que unifica vários métodos de estatística multivariada num quadro metodológico único.

Após a recolha dos dados, os mesmos foram tratados recorrendo a três *softwares* distintos tendo em vista a estimação individual das *proxies*. Primeiro, foi utilizado o *Statistical Analysis System (SAS)* por forma a

depurar, construir e tratar a base de dados. De seguida, a mesma foi transposta para o *Statistical Package for the Social Sciences (SPSS)*, onde foram definidas as variáveis e as *proxies* que servem de base à explicação do modelo de análise. Posteriormente, recorrendo ao *software Analysis of Moments Structures (AMOS)* foi especificado o modelo de análise e estimados todos os parâmetros constituintes do mesmo. A estimação destes parâmetros foi efetuada com recurso ao método da Máxima Verosimilhança (*ML*) uma vez que este produz estimativas dos parâmetros centradas e consistentes, sendo que à medida que a dimensão da amostra aumenta, as estimativas aproximam-se do verdadeiro valor do parâmetro populacional, com variância mínima e distribuição normal (Marôco, 2014).

Com a estimação dos parâmetros efetuada, elaborou-se, de seguida, uma análise descritiva quer da amostra, quer das *proxies* que fazem parte do modelo, recorrendo-se, para tal, às clássicas estatísticas descritivas (Média, Desvio Padrão, Máximos e Mínimos). Seguidamente, com o intuito de avaliar se o modelo teórico é adequado para as pretensões da presente investigação, foram avaliados os pressupostos basilares da AEE e efetuadas as necessárias correções para que os mesmos fossem cumpridos. Posteriormente, de forma a avaliar a qualidade com que o modelo teórico reproduz as correlações esperadas entre as variáveis, foi efetuada uma avaliação da qualidade do ajustamento global com recurso aos principais índices de qualidade constantes do *output* produzido pelo *AMOS*. Por fim, avaliou-se a significância dos parâmetros com o intuito de se perceber a validade dos mesmos, a sua capacidade de medir com maior fiabilidade a QIF e a validação, ou não, das hipóteses inerentes ao desenvolvimento da investigação.

2.4. MODELO DE ANÁLISE

Depois de apresentados o objetivo do estudo, as hipóteses de investigação, a amostra e o tratamento efetuado aos dados, importa definir o modelo de análise que representa a base do presente artigo. Deste modo, e considerando as *proxies* que sustentam as hipóteses de investigação e consequentemente o problema central da presente investigação, resultou o modelo de análise que se apresenta de seguida na **Figura 1**.

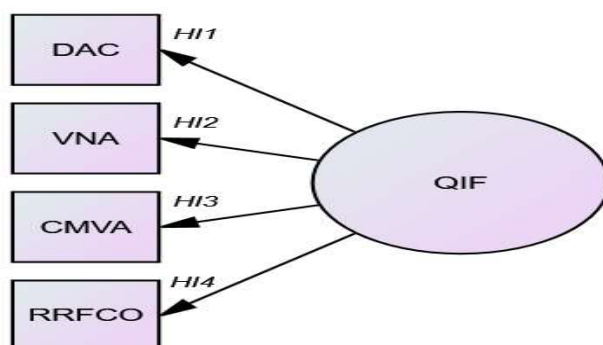


Figura 1: Modelo de análise

O modelo supra indica a QIF como variável latente que se tenta medir com recurso à estimação conjunta das *proxies* aí representadas através da utilização de um MEE. Ora este facto tenta rebater uma lacuna constantemente apontada aos mais variados estudos sobre a QIF, que se prende com o facto de por norma, estes estudos estimarem a QIF tendo por base apenas uma das *proxies* agora utilizadas. Deste modo, com a seleção de mais variáveis pretende-se conceder maior robustez ao estudo da QIF, uma vez que se espera que estas sejam variáveis com elevado carácter explicativo da QIF. Em seguida explica-se cada uma das *proxies*, tendo por base o referenciado sobre estas na revisão da literatura.

O modelo [1] representa a *proxy* da manipulação de resultados discricionária tendo por base o modelo de Jones (1991) previamente apresentado na revisão da literatura e que aqui se transpõe novamente:

$$AT_{i,t} = \alpha + \beta_1 \Delta VN_{i,t} + \beta_2 AFT_{i,t} + \varepsilon_{i,t} \quad [1]$$

Com a utilização desta *proxy*, pretende-se detetar práticas de manipulação discricionária de resultados bem como quaisquer ajustamentos, erros ou omissões não propositados que prejudiquem a IF e que consequentemente reduzam a QIF. Como referenciado na revisão da literatura, o modelo de Jones (1991) tem em consideração a variação do volume de negócios e o nível dos ativos fixos tangíveis como variáveis explicativas dos DAC. Quanto aos resíduos do modelo, estes representam a componente discricionária que se

pretende estudar e o seu resultado indica que quanto mais longe de zero estiver, maior será a manipulação dos resultados.

Relativamente ao modelo [2] que de seguida se apresenta, trata-se, segundo o descrito anteriormente na presente investigação, da *proxy* normalmente utilizado para detetar a manipulação real das vendas e foi desenvolvido por Roychowdhury (2006):

$$\frac{FCO_t}{A_{t-1}} = \alpha_1 + \alpha_2 \frac{1}{A_{t-1}} + \alpha_3 \frac{VEPS_t}{A_{t-1}} + \alpha_4 \frac{\Delta VEPS_t}{A_{t-1}} \varepsilon_t \quad [2]$$

O modelo [2] representa a *proxy* utilizada para detetar se as entidades recorrem a mecanismos de manipulação real das vendas como forma de modificar o seu reporte de IF. Este modelo foi proposto por Roychowdhury (2006) e assenta no pressuposto dos FCO normais serem aqueles que uma empresa deveria registar caso não existisse manipulação real das vendas. Deste modo, os FCO anormais que serão dados pelos resíduos do modelo, identificam a existência de comportamentos anormais no volume de negócios (VNA) das empresas que se verificam com maior intensidade caso o seu valor se afaste mais do zero.

Quanto ao modelo [3], o mesmo foi também proposto por Roychowdhury (2006) e é, como explanado na revisão da literatura, normalmente utilizado para detetar quaisquer manipulações no CMV:

$$\frac{CMV_t}{A_{t-1}} = \alpha_1 + \alpha_2 \frac{1}{A_{t-1}} + \alpha_3 \frac{VEPS_t}{A_{t-1}} + \varepsilon_t \quad [3]$$

Quanto ao modelo [3], trata-se do segundo modelo desenvolvido por Roychowdhury (2006) e neste caso visa identificar a existência de CMVA em relação ao volume de negócios apresentado. Tal como nos casos anteriores, quando mais afastado o valor anormal do CMV se encontrar de zero maior é a manipulação do mesmo e consequentemente pior é a QIF.

Quanto à relação entre resultados e FCO (RRFCO), tal como foi explanado na revisão da literatura, esta é positiva caso ambos possuam o mesmo sinal, isto é, quando o EBITDA é positivo, os FCO também serão e vice-versa. Deste modo, esta variável observável assume-se como uma variável *dummy* que assume o valor de 0 caso a relação seja positiva e 1 caso esta seja negativa. Com isto, tenta-se provar que as empresas cuja relação seja positiva apresentam uma maior QIF e caso a relação seja negativa assumir-se-á que tal se deve a atos de adulteração da IF.

Importa referir que os modelos [1], [2] e [3] apresentados são estimados em *cross-section* por ano e por indústria (CAE V.3 a 2 dígitos), sempre que esta tenha pelo menos 15 observações (e.g., Roychowdhury, 2006) na amostra-base.

2.5. PRESSUPOSTOS DO MODELO DE EQUAÇÕES ESTRUTURAIS

Como já referenciado anteriormente, na elaboração do presente artigo é utilizada a AEE como técnica de modelação para testar a validade do modelo de análise. Deste modo, para que se possa avaliar a plausibilidade do modelo teórico, torna-se necessário que sejam validados um conjunto de pressupostos sem os quais os resultados das análises e as conclusões obtidas podem ser comprometidos (Marôco, 2014). No presente artigo são discutidos os seguintes pressupostos de acordo com Marôco (2014): independência de observações, normalidade multivariada, ausência de multicolinearidade e inexistência de *outliers*. De seguida, são analisados, individualmente, cada um dos pressupostos da AEE acima enunciados bem como as formas de verificar a sua validade.

De acordo com Marôco (2014), um princípio básico da AEE é o de que as observações de sujeitos diferentes são independentes entre si. O mesmo autor refere que este pressuposto se assegurará cumprido com a utilização de práticas de amostragem aleatória. Marôco (2014) refere ainda que a violação da independência das observações origina, normalmente, um acréscimo das estimativas dos erros-padrão dos parâmetros e um acréscimo de erros de tipo II (i.e., concluir pela não significância de um parâmetro que é, na população, significativo).

Quando se utilizam os métodos de estimação da *ML* ou o método dos Mínimos Quadrados Generalizados (GLS) é necessário que as variáveis manifestas apresentem distribuição normal multivariada (Marôco, 2014). De acordo com Marôco (2014), a validação deste pressuposto é efetuada através da avaliação das medidas de forma da distribuição (assimetria e curtose) das variáveis manifestas. Ora segundo o mesmo autor, a distribuição normal apresenta assimetria (*sk*) e curtose (*ku*) igual a zero. Deste modo se todas as variáveis manifestas apresentarem valores próximos de zero, este pressuposto encontra-se validado. Todavia, torna-se necessário saber que desvios à normalidade comprometem a fiabilidade das conclusões. Assim, segundo Finney e DiStefano (2006), produzem-se resultados enviesados sempre que $|sk| > 2$ e $|ku| > 7$. Quanto à curtose multivariada (ku_M), os resultados consideram-se enviesados sempre que este valor seja superior a 10 (Marôco, 2014).

Relativamente ao pressuposto da ausência de multicolinearidade, este diz que as variáveis independentes não podem estar fortemente associadas (Marôco, 2014). De acordo com O'Brien (2007) a avaliação da multicolinearidade entre as variáveis manifestas deverá efetivar-se através da utilização do Fator de Inflação da Variância (*VIF*) ou da Tolerância. Deste modo, um valor do *VIF* superior a 5 ou um valor de Tolerância inferior a 0,20 indicam a presença de possíveis problemas com a multicolinearidade. A existência desta forte associação entre as variáveis manifestas indicia a necessidade de reconsiderar o modelo, eliminando a variável em causa (Serapicos, 2016).

Por fim, para que os resultados que advêm de um modelo não possam ser comprometidos, é necessário que não existam *outliers*, ou seja, é importante que quaisquer observações que caíam fora da tendência das restantes sejam removidas (Marôco, 2014). De acordo com Marôco (2014), a presença de *outliers* pode inflacionar ou reduzir as covariâncias entre variáveis e consequentemente nas estimativas das médias, desvios-padrão e covariâncias, comprometendo deste modo a qualidade do ajustamento do modelo. O mesmo autor refere que, por norma, o diagnóstico de possíveis *outliers* é efetuado através da Distância de Mahalanobis (D^2). Esta consiste no cálculo de duas probabilidades (p_1 e p_2), que sempre que inferiores a 0.05 se considera essa observação como um *outlier* multivariado (Marôco, 2014).

2.6. QUALIDADE DO AJUSTAMENTO DO MODELO DE EQUAÇÕES ESTRUTURAIS

Após a validação dos pressupostos anteriormente referenciados, importa avaliar a qualidade do ajustamento do modelo. Esta fase tem como objetivo primordial avaliar o quão bem o modelo teórico é capaz de reproduzir a estrutura correlacional das variáveis manifestas na amostra sob estudo (Marôco, 2014). Segundo Marôco (2014), existem dezenas de estatísticas que podem ser utilizadas para a avaliação da qualidade do ajustamento, as quais podem ser agrupadas em três grupos: i) testes de ajustamento; ii) índices empíricos que se baseiam nas funções de verosimilhança ou na matriz de resíduos obtidos durante o ajustamento do modelo; e iii) com a análise dos resíduos e da significância dos parâmetros. Neste subponto será feita uma análise detalhada a cada um destes três grupos dando-se exemplos das estatísticas e índices mais relevantes e utilizados com maior frequência na literatura.

Dentro do primeiro grupo definido de testes encontra-se o teste do Qui-quadrado (X^2) de ajustamento cujo principal objetivo é testar se a matriz de covariância populacional não difere significativamente da matriz de covariância estimada pelo modelo (Marôco, 2014). Embora seja amplamente usado para avaliar a qualidade do ajustamento dos modelos, este teste é referido como uma inutilidade na medida em que testa uma hipótese que à partida nem se quer é credível, uma vez que este avalia se o ajustamento é perfeito, o que, com facilidade, pode ser considerado falso pois qualquer modelo terá sempre associado algum grau de erro (Marôco, 2014). Para além disto, são também apontadas limitações a este teste ligadas à dimensão da amostra. Marôco (2014) refere que para amostras pequenas estes testes de ajustamento têm grandes probabilidades de erro de tipo II¹ e, para amostras grandes, existem probabilidades acrescidas de erros de tipo I². Quanto a valores de referência para o teste, assume-se que quanto menor, melhor com $p\text{-value} > 0.05$.

Para obviar as claras limitações do teste do Qui-quadrado de ajustamento foram desenvolvidas diversas outras medidas de qualidade sendo que a ideia base destas é quantificar a qualidade de ajustamento do modelo face a modelos de referência. Este segundo grupo de testes pode ser classificado segundo Marôco (2014) em cinco grandes famílias: a) Índices absolutos; b) Índices relativos; c) Índices de parcimónia; d)

¹ Erros de tipo II: não rejeitar um modelo com mau ajustamento.

² Erros de tipo I: rejeitar um modelo com bom ajustamento.

Índices de discrepância populacional; e) Índices baseados na teoria da informação. Nos parágrafos seguintes é descrita a utilidade de cada uma destas famílias de índices assim como alguns exemplos de cada um deles.

Segundo Marôco (2014), os índices absolutos avaliam a qualidade do modelo *per se*, sem quaisquer comparações com outros modelos sendo de destacar como exemplos o rácio X^2 /graus de liberdade (gl) e *Goodness of Fit Index* (GFI). Para o primeiro exemplo, considera-se um ajustamento perfeito do modelo quando o resultado do rácio é igual a 1, bom para um resultado inferior a 2-3, aceitável para valores inferiores a 5 e inaceitável para valores superiores a este último (Marôco, 2014; Wheaton, 1987). Quanto ao GFI, o mesmo autor refere que o ajustamento perfeito ocorre quando o valor é igual a 1, muito bom para valores superiores a 0.95, bom para valores entre 0.90 e 0.95 e mau para valores inferiores a 0.90 (Marôco, 2014; Tanaka & Huba, 1985).

Relativamente aos índices relativos, de acordo com Marôco (2014) avaliam a qualidade do modelo sob teste relativamente: i) ao modelo com pior ajustamento possível (modelo de independência: não há relações entre quaisquer variáveis manifestas) e/ou ii) ao modelo com melhor ajustamento possível (modelo saturado: todas as variáveis manifestas estão correlacionadas). Os principais exemplos deste tipo de índices são o *Comparative Fit Index* (CFI) e o *Normed Fit Index* (NFI). O primeiro, à semelhança dos anteriores, apresenta um ajustamento perfeito quando igual a 1, muito bom quando superior a 0.95, bom para valores entre 0.9 e 0.95 e mau para valores inferiores a 0.9 (Bentler, 1990). Relativamente ao NFI, os valores aceites são em tudo semelhantes ao CFI, no entanto, só se considera como possuindo um mau ajustamento para valores inferiores a 0.8 (Bentler & Bonett, 1980).

Quanto aos índices de parcimónia, estes são obtidos corrigindo os índices relativos por um fator de penalização associado à complexidade do modelo. O seu principal objetivo é compensar a melhoria artificial do modelo que se consegue, simplesmente, por inclusão de mais parâmetros livres aproximando o modelo sob estudo ao modelo saturado (Marôco, 2014; Mulaik et al., 1989). De entre os principais índices destacam-se o *Parsimony CFI*, *Parsimony GFI* e *Parsimony NFI*. Para estes, os valores de referência para um bom ajustamento são inferiores aos dos correspondentes índices relativos uma vez que se considera com um bom ajustamento valores superiores a 0.8, razoável para valores entre 0.6 e 0.8 e mau para valores inferiores a 0.6 (Marôco, 2014; Mulaik et al., 1989).

Os índices de discrepância populacional avaliam se o modelo ajustado é aproximadamente correto (em oposição a 100% correto do teste do X^2). Segundo Marôco (2014), esta avaliação consome-se através da comparação entre o ajustamento do modelo obtido com os momentos amostrais (médias e variâncias amostrais) e o ajustamento do modelo que se obteria com os momentos populacionais (médias e variâncias populacionais) (Marôco, 2014). O exemplo mais utilizado deste tipo de índices é o *Root Mean Square Error of Approximation* (RMSEA) cujos *softwares* calculam um intervalo de confiança de 90% e um ajustamento muito bom para valores inferiores a 0.05, bom para valores entre 0.05 e 0.08, medíocre entre 0.08 e 0.10 e inapropriado para valores superiores (Arbuckle, 2009; Marôco, 2014).

Relativamente aos índices baseados na teoria da informação, de acordo com Marôco (2014), estes são baseados na estatística X^2 e penalizam o modelo em função da sua complexidade. Estes índices não apresentam quaisquer valores de referência para classificar o ajustamento do modelo sendo apenas apropriados apenas quando é necessário comparar vários modelos alternativos que se ajustem aos dados (Marôco, 2014). Deste modo, o melhor modelo será, de entre os avaliados, aquele que apresentar os menores valores em um ou mais dos seguintes índices de referência (Arbuckle, 2009): i) *Akaike Information Criterion*; ii) *Browne-Cudeck Criterion*; iii) *Bayes Information Criterion*; e iv) *Expected Cross-Validation Index*.

Mesmo que um modelo apresente um bom ajustamento global, ainda assim poderá apresentar um mau ajustamento local, ou seja, os índices de ajustamento global podem indicar um bom ajustamento, todavia um ou mais parâmetros do modelo podem não ser significativos e ou a fiabilidade de um ou mais indicadores ser reduzida (Marôco, 2014). O diagnóstico deste tipo de problemas pode fazer-se através de várias estatísticas sendo as mais usuais as seguintes: i) avaliação dos resíduos estandardizados; ii) avaliação dos erros-padrão assintóticos dos parâmetros do modelo e sua significância; e iii) avaliação da fiabilidade individual das variáveis manifestas (Marôco, 2014). Deste modo, Marôco (2014) recomenda que para a avaliação da qualidade do ajustamento do modelo se usem várias medidas de ajustamento global e local e, caso estas sejam concordantes, o investigador pode concluir que o modelo reproduz, convenientemente, a estrutura relacional observada entre as variáveis.

3. APRESENTAÇÃO E ANÁLISE DOS RESULTADOS

Neste ponto são apresentados e analisados os resultados obtidos da presente investigação. Numa primeira fase, efetua-se uma caracterização da amostra com recurso a uma análise descritiva dos dados tendo em conta a natureza das variáveis. Com efeito, para tal caracterização, utilizam-se medidas estatísticas como a média, o desvio-padrão, o valor mínimo e o valor máximo. Posteriormente avalia-se o cumprimento dos pressupostos associados à AEE bem como a qualidade do ajustamento global do modelo. Por fim, apresentam-se as estimativas estandardizadas que servem de suporte à apresentação e discussão dos resultados obtidos.

3.1. CARATERIZAÇÃO DA AMOSTRA

Previamente à apresentação dos resultados obtidos com o modelo de análise, torna-se da máxima importância compreender a amostra em apreço. Deste modo, torna-se imprescindível perceber quais as atividades desenvolvidas pelas empresas constantes da amostra. Na Tabela encontram-se sintetizadas as principais atividades empresariais desenvolvidas pelas empresas em estudo segundo a sua Classificação de Atividade Económica (CAE).

Tabela 2: Atividades das empresas

Atividade	Empresas (n)	Empresas (%)	Observações (n)	Observações (%)
APD	20	0,1	68	0,1
ALR	1 139	4,6	4 888	4,5
ADM	958	3,8	4 327	4,0
ART	197	0,8	863	0,8
CIE	1 596	6,4	6 341	5,9
INF	632	2,5	3 135	2,9
SAU	560	2,2	2 623	2,4
FIN	892	3,6	3 492	3,2
IMO	2 598	10,4	5 695	5,3
AGU	277	1,1	1 496	1,4
COM	6 210	24,9	27 993	25,8
CON	2 408	9,7	9 418	8,7
EDU	177	0,7	896	0,8
ELE	361	1,4	1 888	1,7
IND	5 837	23,4	29 712	27,4
OUT	44	0,2	206	0,2
TRA	1 033	4,1	5 264	4,9
Total	24 939	100	108 305	100

Notas:

APD – Administração pública e defesa; segurança social obrigatória / ALR – Alojamento e restauração / ADM – Atividades administrativas e dos serviços de apoio / ART – Atividades artísticas, de espetáculos, desportivas e recreativas / CIE – Atividades de consultoria, científicas, técnicas e similares / INF – Atividades de informação e de comunicação / SAU – Atividades de saúde humana e apoio social / FIN – Atividades financeiras e de seguros / IMO – Atividades imobiliárias / AGU – Captação, tratamento e distribuição de água; saneamento, gestão de resíduos e despoluição / COM – Comércio por grosso e a retalho; reparação de veículos automóveis e motociclos / CON – Construção / EDU – Educação / ELE – Eletricidade, gás, vapor, água quente e fria e ar frio / IND – Indústrias transformadoras / OUT – Outras atividades de serviços / TRA – Transportes e armazenagem

Fonte: Elaboração própria

Da observação da Tabela conclui-se que a atividade económica com maior contribuição para a amostra de 24.939 empresas é o comércio por grosso e a retalho com 6.210 empresas que representam 24,9% do universo em estudo. É também possível observar que as indústrias transformadoras e as empresas imobiliárias completam o top 3 das empresas com maior representatividade na amostra, representando, em conjunto, 58,7% do seu total. Já a atividade económica com menor representatividade na amostra é a Administração pública e defesa com apenas 20 empresas presentes na amostra. Quanto às observações, estas são o reflexo do número de anos que, após o processo de depuração da amostra, cada empresa tem. Como é natural, a atividade de comércio por grosso e a retalho e a das indústrias transformadoras são também as mais representativas no total das 108.305 observações representando 53,3%. Na Tabela são apresentadas algumas estatísticas descritivas das variáveis em estudo (excetuando a RRFCO, visto que esta se trata de uma variável *dummy*) bem como de outras características genéricas da amostra em estudo.

Tabela 3: Estatísticas descritivas da amostra

Caraterísticas da amostra	Média	Desvio Padrão	Máximo	Mínimo
Caraterísticas Genéricas				
Total de ativo	16 396 233	56 639 862	2 314 786 954	5 636
Volume de negócios	10 783 816	48 523 830	2 990 408 710	0
EBITDA	1 154 787	7 097 553	459 890 879	-428 058 000
Caraterísticas das variáveis				
DAC	0,155	0,182	1,000	0,000
VNA	0,156	0,172	1,000	0,000
CMVA	0,141	0,160	0,969	0,000

Fonte: Elaboração própria

Analisando a estatística descritiva das caraterísticas genéricas da amostra constata-se que, pese embora os máximos indiquem a presença de grandes empresas na amostra, observando a média das rubricas de volume de negócios e total de ativo, verifica-se que a maior parte das empresas se trata de PME. Quanto às caraterísticas das variáveis, como já referenciado anteriormente, quanto mais distante de zero pior será a QIF. Deste modo, analisando os máximos, estes indiciam a existência de variáveis que possivelmente prejudicam a QIF uma vez que se aproximam do 1.

3.2. ANÁLISE DOS PRESSUPOSTOS DO MODELO

Antes de se passar à análise concreta dos resultados obtidos com o modelo, afigura-se como sendo da máxima importância avaliar se os pressupostos subjacentes à AEE são cumpridos na íntegra. Com efeito, nesta etapa é efetuada a análise dos pressupostos do modelo tendo em conta o sugerido pelos estudos de Finney e DiStefano (2006), Marôco (2014), O'Brien (2007) e Serapicos (2016). De seguida é analisado o cumprimento dos pressupostos da independência de observações, inexistência de *outliers*, normalidade multivariada e ausência de multicolinearidade.

Quanto ao pressuposto da independência, para que este seja cumprido, as observações de sujeitos diferentes têm de ser independentes entre si. Assim, o pressuposto da independência de observações considera-se como integralmente cumprido uma vez que todo o processo de seleção da amostra foi efetuado com recurso a práticas de amostragem aleatória. Desta forma, não resulta qualquer enviesamento nos resultados obtidos.

Relativamente ao pressuposto da inexistência de *outliers*, este efetua-se analisando o D^2 . Nem todos os valores elevados nas variáveis refletem *outliers*, alguns podem refletir observações extremas, reais, que poderá ser necessário considerar, não devendo o processo de eliminação das observações obedecer somente a critérios estatísticos mas também ao bom senso do investigador (Marôco, 2014). Com efeito, consultando o *output*, dado pelo *software* AMOS, verificou-se que existem dezenas de observações consideradas *outliers*. Seguindo as indicações de Marôco (2014) foram retiradas as observações com D^2 maior e foi de novo testado o modelo. Da análise efetuada, não se verifica uma melhoria significativa nos índices de qualidade do modelo e, para além disto, com a eliminação destas observações surgem novas observações que à partida não são consideradas *outliers*. Assim, opta-se pela não eliminação de observações uma vez que nos passos de depuração da base de dados já se eliminaram os extremos superiores e inferiores da amostra, resultando apenas os valores entre 0 e 1 nas variáveis.

Tal como referenciado anteriormente, quando se utiliza a *ML* como método de estimação do modelo, que é o caso do presente estudo, é necessário que se faça cumprir o pressuposto da normalidade multivariada. Lembra-se que este pressuposto se pode considerar integralmente cumprido sempre que se verifique que $|sk| < 2$, $|ku| < 7$ e $ku_M < 10$. De forma a sintetizar os resultados obtidos relativamente ao cumprimento deste pressuposto, apresenta-se a Tabela 4 na qual é possível constatar que os valores obtidos para *sk* e *ku* não indicam qualquer violação do pressuposto da normalidade. Todavia, analisando o valor de ku_M , verifica-se uma violação séria do pressuposto da normalidade o que torna imperativo a utilização de mecanismos de normalização das variáveis quer seja através de transformações matemáticas, *bootstrap* ou métodos de estimação que dispensem o cumprimento deste pressuposto (Marôco, 2014).

Tabela 4: Avaliação da normalidade do modelo

Variável	<i>sk</i>	Rácio Crítico	<i>ku</i>	Rácio Crítico
RRFCO	1,036	139,146	-0,927	-62,298
CMVA	2,000	268,677	4,487	301,396
VNA	2,044	274,573	4,674	313,981
DAC	2,111	283,663	4,663	313,276
<i>ku_M</i>			17,093	405,970

Fonte: Elaboração própria

Com a verificação do não cumprimento integral do pressuposto a normalidade, e tal como sugerido por Marôco (2014), optou-se por utilizar transformações matemáticas de forma a normalizar as variáveis. Com efeito, recorreu-se à raiz quadrada como método matemático de normalização das variáveis, tal como sugerido pelo autor. Deste modo, os novos valores de *sk*, *ku* e *ku_M* para as variáveis em estudo são os que se explanam na Tabela .

Tabela 5: Avaliação da normalidade do modelo com transformação matemática

Variável	<i>sk</i>	Rácio Crítico	<i>ku</i>	Rácio Crítico
RRFCO	1,036	139,146	-0,927	-62,298
CMVA	0,774	103,982	0,221	14,876
VNA	0,817	109,76	0,429	28,789
DAC	0,956	128,447	0,595	39,952
<i>ku_M</i>			1,923	45,663

Fonte: Elaboração própria

De acordo com a tabela supra, todos os valores ($|sk| < 2$, $|ku| < 7$ e $ku_M < 10$) são indicativos do cumprimento do pressuposto da normalidade multivariada. Deste modo, assegura-se que a estimação do modelo possa ocorrer através do método inicialmente estipulado (*ML*) cuja utilização garante a produção de resultados mais eficientes e consistentes que os demais métodos de estimação (Marôco, 2014).

Por último, é avaliada a existência de uma forte associação entre as variáveis. Estando na presença de multicolinearidade, uma variável independente pode escrever-se como uma combinação (quase) perfeita das outras variáveis quer manifestas quer latentes (Marôco, 2014). Assim, na Tabela encontram-se explanadas as estatísticas (Tolerância e *VIF*) de avaliação da multicolinearidade

Tabela 6: Avaliação da multicolinearidade

Variáveis	Tolerância	<i>VIF</i>
DAC	0,946	1,057
VNA	0,883	1,133
CMVA	0,930	1,075
RRFCO	0,987	1,013

Fonte: Elaboração própria

Como é possível observar na Tabela , todas as variáveis (depois da sua normalização) apresentam um *VIF* menor que 5 e uma tolerância inferior a 0,200 o que, de acordo com O'Brien (2007), significa que não existem quaisquer problemas de multicolinearidade presentes no modelo.

Analisados os pressupostos da AEE, constata-se que todos eles se encontram totalmente cumpridos. Sendo que o único caso que poderia causar enviesamento dos resultados seria a possível existência de *outliers*. Todavia, pelas razões apresentadas anteriormente verifica-se que estes se tratam de falsos positivos. Deste modo, é possível avançar para a fase seguinte da AEE, que avalia a qualidade do ajustamento do modelo.

3.3. AVALIAÇÃO DA QUALIDADE DO AJUSTAMENTO DO MODELO

Nesta fase procede-se à avaliação da qualidade do ajustamento do modelo através da utilização dos testes de diagnóstico enumerados na metodologia. Ressalva-se que a avaliação da qualidade do ajustamento dos modelos é uma das fases menos consensuais da AEE uma vez que são várias as estatísticas que podem ser utilizadas e vários inconvenientes que podem estar associados às mesmas (Marôco, 2014). Desta forma, na Tabela 7 são apresentados os resultados dos testes de diagnóstico efetuados ao ajustamento do modelo.

Tabela 7: Testes de qualidade do ajustamento global do modelo

Teste	Resultado
X^2	584,68 (P-value=0,000)
X^2/gl	292,340
GFI	0,997
CFI	0,960
NFI	0,960
RMSEA	0,052

Fonte: Elaboração própria

De acordo com os resultados apresentados na tabela supra, constata-se que o modelo apresenta, de um modo geral, indicadores de um bom ajustamento. Todavia, os resultados reportados pelo X^2 e pelo X^2/gl traduzem uma qualidade do ajustamento inaceitável. Como referido anteriormente, o resultado apresentado por este teste pode ser considerado enviesado por três fatores (Marôco, 2014): i) o X^2 testa se um modelo é perfeito, o que é considerado uma nulidade, uma vez que qualquer modelo tem sempre um grau de erro; ii) o X^2 possui uma elevada sensibilidade à dimensão da amostra, originando erros de tipo I para amostras grandes e tipo II para amostras pequenas; e iii) o X^2 é sensível à violação do pressuposto da distribuição normal das variáveis manifestas.

Uma vez que o pressuposto da distribuição normal se encontra cumprido, importa perceber se o X^2 está a reportar um possível erro tipo I, rejeitando a hipótese de que o modelo se ajusta bem aos dados quando de facto o ajustamento é bom. Como refere Marôco (2014), para amostras com $n > 400$, este teste é quase sempre significativo ($p < 0,05$) originando uma qualidade do ajustamento global do modelo inaceitável. Dado que a amostra em estudo contém 108.305 observações, tal facto origina um valor muito elevado para o X^2 .

De forma a resolver os problemas associados ao X^2 foram criadas diversas medidas estatísticas que visam quantificar a qualidade do ajustamento global do modelo tendo por base as imprecisões do X^2 (Marôco, 2014). Com efeito, tendo em conta o descrito na metodologia e analisando os outros índices de ajustamento presentes na Tabela 7, estes indicam um grau de ajustamento global do modelo muito bom. Assim, torna-se essencial avaliar a qualidade de ajustamento local do modelo, ou seja, se as estimativas estandardizadas dos parâmetros constantes do modelo são estatisticamente significativas e fiáveis.

3.4. ESTIMATIVAS ESTANDARDIZADAS E DISCUSSÃO DOS RESULTADOS

Após a análise efetuada aos pressupostos da AEE e à qualidade do ajustamento global do modelo de análise é fulcral que se avalie a significância dos parâmetros que compõem o mesmo. Este diagnóstico é efetuado através da avaliação dos valores de cada um dos pesos fatoriais estandardizados (λ). Deste modo, neste ponto, analisa-se a validade fatorial, as fiabilidades individuais (R^2) e a correspondente significância de cada uma das trajetórias (hipóteses) do MEE. Para tal, na Figura 2 apresentam-se os pesos fatoriais estandardizados (valores acima de cada um dos caminhos direcionais) e os correspondentes R^2 (valores acima de cada uma das variáveis manifestas).

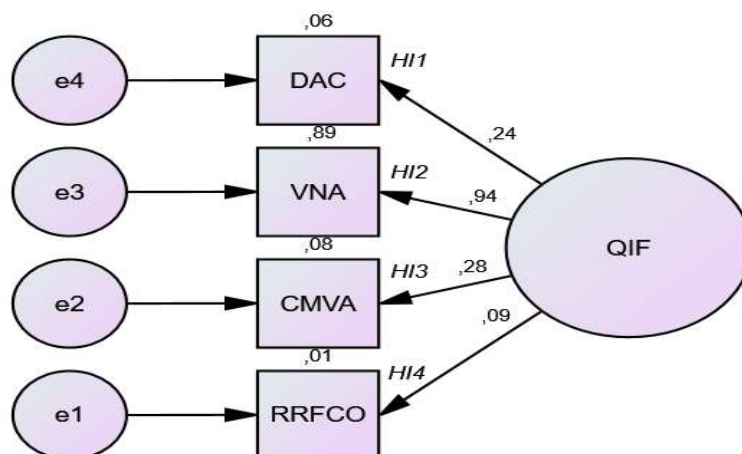


Figura 2: Modelo de equações estruturais com estimativas estandardizadas

De acordo com Marôco (2014), um MEE apresenta validade fatorial sempre que os pesos fatoriais forem superiores ou iguais a 0,5. O mesmo autor considera ainda que os diferentes fatores são fiáveis quando o R^2 é superior a 0,25. Observando a Figura 2, conclui-se que apenas as vendas anormais cumprem estas condições ($\lambda = 0,94$; $R^2 = 0,89$), ou seja, são o único fator do modelo com suficiente validade para operacionalizar a variável latente (QIF). Tal facto não invalida que os restantes fatores possam ser estatisticamente significativos e que as restantes hipóteses não possam também elas ser validadas, apenas indica que o seu peso no modelo não é tão significativo, não possuindo validade suficiente para medir a QIF com a necessária fiabilidade (Marôco, 2014). Assim, e como importa agora perceber se, apesar de os restantes fatores apresentarem validade e fiabilidade individuais muito reduzidas, as hipóteses de investigação são confirmadas, apresenta-se a Tabela com a síntese dos resultados obtidos com a presente investigação.

Tabela 8: Síntese dos resultados obtidos

	Hipóteses	Peso fatorial	P-value	Resultado
H_{1}	Os DAC influenciam negativamente a QIF	0,24	<0,01	Confirmada
H_{2}	O valor anormal das vendas influencia negativamente a QIF	0,94	<0,01	Confirmada
H_{3}	O valor anormal do custo das mercadorias vendidas influencia negativamente a QIF	0,28	<0,01	Confirmada
H_{4}	Se os FCO e o EBITDA apresentarem o mesmo sinal, ou seja, ambos positivos ou ambos negativos, isso influencia positivamente a QIF	0,09	<0,01	Confirmada

Fonte: Elaboração própria

Observando a tabela supra, percebe-se que, pese embora o diminuto contributo de algumas para a medição da QIF, todas as variáveis são estatisticamente significativas e todos os pesos fatoriais apresentam sentidos positivos, conseqüentemente todas as hipóteses formuladas são confirmadas. Percebe-se que a variável com menor carácter explicativo da QIF é a relação entre os fluxos de caixa operacionais e o EBITDA e que, pelo contrário, a que apresenta maior peso para a quantificação da QIF é o valor anormal das vendas. Pelo meio aparecem os DAC e o valor anormal do CMV como variáveis explicativas com pesos não tão fiáveis, mas com igual significância estatística. Atente-se no facto de a QIF perfeita se traduzir por $QIF = 0$, deste modo, quanto mais longe estiver o valor do peso fatorial, pior será a QIF.

Relativamente à primeira hipótese de investigação, pretende-se perceber se os DAC influenciam negativamente a QIF. Como é possível observar na Tabela, sempre que a QIF varia uma unidade de desvio padrão, os DAC variam 0,24 unidades de desvio padrão, o que origina uma redução da QIF, já que o valor se afasta positivamente de zero. Tal conclusão vai de encontro aos trabalhos anteriores (e.g., Carmo, 2013; Chen et al., 2018; Dechow et al., 2012; Gutiérrez & Rodríguez, 2017). No entanto, vem contrapor a ideia generalizada de que a QIF se mede somente através de uma das *proxies*, por exemplo dos DAC, uma vez que esta *proxy* nem sequer é a que possui um maior peso fatorial no modelo.

Quanto à segunda hipótese de investigação, seguindo o mesmo sentido da anterior, tenta-se perceber se o VNA influencia negativamente a QIF. Da análise à Tabela, conclui-se que sempre que a QIF aumenta uma unidade de desvio padrão (piora uma unidade), o VNA aumenta 0,94 unidades de desvio padrão. Assim,

valida-se esta hipótese, já que a redução da QIF é significativamente acompanhada pelos mecanismos de adulteração das vendas tal como descrito em alguns estudos sobre o tema (e.g., Alves & Moreira, 2014; Ge & Kim, 2014; Roychowdhury, 2006).

Em relação ao valor anormal do CMV, infere-se que sempre que a QIF se agrava uma unidade de desvio padrão, este segue o mesmo sentido em 0,28 unidades de desvio padrão. Assim, depreende-se que o deteriorar da QIF é acompanhado pela utilização de mecanismos de manipulação real do CMV. Desta forma, valida-se a terceira hipótese de investigação e prova-se que estes mecanismos prejudicam a percepção que os *stakeholders* possam ter da IF tal como referenciado nos trabalhos de investigação de Alves e Moreira (2014), Cohen et al. (2008) e Roychowdhury (2006).

No que se refere à relação entre EBITDA e FCO, da análise à Tabela , percebe-se que, não obstante a sua reduzida fiabilidade individual, este fator segue o mesmo sentido do agravamento da QIF, isto é, quando a QIF piora uma unidade de desvio padrão, a RRFÇO varia 0,09 unidades de desvio padrão. Recorde-se que esta se trata de uma variável *dummy* que assume o valor 0 quando a relação seja positiva e 1 caso esta seja negativa. Deste modo, conclui-se que o agravamento da QIF se deve, ainda que parcamente, ao facto de as empresas apresentarem sinais do EBITDA e dos FCO opostos. Com efeito, conclui-se pela validação da quarta hipótese de investigação na medida em que as empresas com uma RRFÇO negativa tendem a possuir uma QIF mais reduzida.

Com a validação das hipóteses acima discriminadas, importa agora apresentar os *scores* estimados para cada uma das variáveis e que se somando quantificarão a QIF de cada empresa para cada ano em análise. Note-se que, como é natural, a ordem dos *scores* com maior influência no cálculo da QIF é a mesma dos pesos fatoriais. Assim, consultando o *output* produzido pelo *software* AMOS, resulta o modelo 4:

$$QIF = 0.141 \times DAC + 4,777 \times VNA + 0.173 \times CMVA + 0.024 \times RRFÇO \quad [4]$$

Observando o modelo 4, consta-te que o item que maior contributo tem para a quantificação da QIF é o VNA com um *score* de 4,777. Verifica-se que, em consonância com os pesos fatoriais anteriormente apresentados, o fator com menor contributo para a quantificação da QIF é a RRFÇO. Com o modelo acima apresentado, torna-se assim possível calcular a QIF para cada uma das entidades-ano (observações) representadas na amostra, a qual constitui, certamente, uma *proxy* mais robusta da QIF e que poderá ser utilizada em diferentes estudos que utilizem a QIF como variável central da análise.

4. CONCLUSÕES, LIMITAÇÕES E LINHAS DE INVESTIGAÇÃO FUTURAS

A pertinência da presente investigação surge do facto de nos trabalhos sobre a QIF, esta ser medida através de uma só variável, muitas das vezes através dos DAC. No entanto, é sabido que a QIF é um conceito multidimensional na medida em que a sua quantificação depende de mais do que uma variável. Com efeito, e aproveitando este *gap* teórico, definiu-se como objetivo primordial deste artigo a construção de um MEE recorrendo à combinação de diferentes *proxies* tendo em vista a aferição com maior robustez e segurança da QIF. Para a persecução do objetivo do estudo, recorreu-se a quatro propriedades da IF que se entendeu terem um elevado grau de correlação com a QIF das empresas, os DAC, o VNA, o CMVA e a relação entre os FCO e o EBITDA. Cada uma destas propriedades deu origem a uma hipótese de investigação, na qual se tentou perceber se o agravamento da QIF está associado à utilização deste tipo de mecanismos de adulteração da IF.

No que concerne ao estudo das hipóteses de investigação, salienta-se que todas elas foram validadas, provando-se que as empresas recorrem, em maior ou menor medida, a este tipo de mecanismos para manipular os seus resultados. A hipótese um comprovou que os DAC influenciam negativamente a QIF. Todavia, o facto de esta ser a segunda variável com menor influência no modelo vai ao encontro daqueles que defendem que esta, embora amplamente usada na literatura, não é a *proxy* mais adequada para a QIF. A hipótese dois comprova que a utilização de mecanismos de manipulação das vendas influencia, em grande medida, o agravamento da QIF. A validação da terceira hipótese consolida a ideia de que as empresas recorrem à adulteração dos CMV como forma de “compor” os seus resultados correntes. Por último, a quarta hipótese de investigação conclui que as empresas que apresentam sinais distintos para o EBITDA e para os FCO possuem, por norma, uma QIF menor.

A validação de todas as hipóteses de investigação vem contribuir em diversas medidas para o melhoramento dos estudos que versem sobre a QIF. Acresce que, tanto quanto se sabe, este é dos primeiros trabalhos que utilizam a AEE como meio de combinação de diversas *proxies* para aferir a QIF. Como tal, contribui com conhecimento teórico e empírico sobre este tema, vindo reforçar a ideia de que a QIF se trata de um conceito multidimensional que se deve medir através de diversas variáveis manifestas indo de encontro ao anteriormente escrito por Chen et al. (2018), Dechow et al. (2012) e Gutiérrez e Rodríguez (2017). Sob o ponto de vista do tamanho da amostra, a presente investigação vem aportar aos resultados uma vasta robustez e segurança, já que o seu tamanho faz com que a amostra em estudo seja bastante heterogénea, quer a nível da dimensão das empresas, quer a nível dos anos em estudo, quer a nível das diversas atividades empresariais representadas.

No que diz respeito a possíveis limitações da investigação, destaca-se a quantidade de variáveis manifestas escolhidas, os pesos fatoriais das mesmas e o condicionamento que o tamanho da amostra causou na avaliação da qualidade do ajustamento global. Relativamente à quantidade de variáveis manifestas escolhidas, aponta-se o facto de uma variável latente poder ser explicada por diversos fatores, como tal quanto mais fatores fossem adicionados maior caráter explicativo teriam da variável latente. Acresce que os pesos fatoriais de três das quatro variáveis manifestas não possuem o caráter explicativo desejado, originando uma validade fatorial e uma fiabilidade individual diminuta. Este facto acaba por condicionar a análise dos resultados obtidos na medida em que os mesmos não apresentam a validade desejada para analisar com total fiabilidade os resultados obtidos. Quanto ao condicionamento que o tamanho da amostra causou na avaliação da qualidade do ajustamento global do modelo, este prende-se com o facto de nas amostras maiores, o X^2 , um dos principais avaliadores da qualidade, produzir resultados enviesados. No entanto, a necessidade de possuir uma amostra desta dimensão era óbvia, visto que a heterogeneidade da amostra traz uma maior robustez aos resultados obtidos.

No sentido de obviar algumas das limitações acima descritas, propõe-se para investigações futuras um acrescento de novas variáveis manifestas ao modelo de análise, uma análise posterior mais aprofundada, uma possível comparação de duas ou mais amostras independentes e uma alternativa metodológica diferente. Como já referenciado, esta investigação trouxe um novo modelo de se avaliar a QIF, ora esta inovação abre portas para que a partir daqui se eliminem variáveis sem caráter explicativo suficiente e se acrescentem outras variáveis de forma a que possa testar com maior fiabilidade a variável latente. Para além disto, sugere-se que seja efetuada uma análise posterior à obtenção dos *scores* do modelo, analisando se a QIF difere consoante o CAE, a dimensão da empresa, a existência ou não de Revisor Oficial de Contas, de entre outras. A comparação dos resultados obtidos com a amostra de empresas portuguesas com outros obtidos em países semelhantes proporcionaria uma perceção diferente sobre a QIF nos mais distintos países e permitiria perceber que países possuem, em média, uma melhor QIF e que motivos estão por detrás desse facto. Por fim, de modo a que se perceba melhor os fatores influenciadores da QIF bem como as suas causas e consequências, sugere-se que seja aplicada uma investigação extensiva de caráter qualitativo.

REFERÊNCIAS

- Alves, J., & Moreira, J. (2014). Accounting and tax fraud through invoiceless sales: Are shareholders loans the visible trace of the underlying money laundering? A study for the portuguese case. Apresentado na XVI Encuentro AECA, Leiria.
- Arbuckle, J. L. (2009). AMOS 18 Users' Guide. Chicago IL: SPSS.
- Banimahd, B., & Aliabadi, M. J. (2013). A study on relationship between earnings management and operating cash flows management: Evidence from Tehran Stock Exchange. *Management Science Letters*, (3), 1677–1682.
- Bentler, P. M. (1990). Comparative fit indexes in structural models. *Psychological Bulletin*, 107, 238–246.
- Bentler, P. M., & Bonett, D. G. (1980). Significance tests and goodness of fit in the analysis of covariance structures. *Psychological Bulletin*, 88, 588–606.
- Caiado, A., & Gil, P. (2014). A Demonstração dos Fluxos de Caixa (2.^a). Lisboa: Áreas Editora.
- Carmo, C. (2013). Custo do financiamento bancário e qualidade da informação financeira (Dissertação de Doutoramento em Contabilidade). Universidade de Aveiro, Aveiro.
- Chen, W., Hribar, P., & Melessa, S. (2018). Incorrect inferences when using residuals as dependent variables. *Journal of Accounting Research*, 56(3), 751–796.
- Cohen, D., Dey, A., & Lys, T. (2008). Real and Accrual-Based Earnings Management in the Pre- and Post-Sarbanes-Oxley Periods. *The Accounting Review*, 83(3), 757–787.
- Dechow, P., & Dichev, I. (2002). The quality of accruals and earnings: The role of accrual estimation errors. *The Accounting Review*, 77, 35–59.
- Dechow, P., Ge, W., & Schrand, C. (2010). Understanding earnings quality: A review of the proxies, their determinants and their consequences. *Journal of Accounting and Economics*, 50, 344–401.

- Dechow, P., Hutton, A., Kim, J., & Sloan, R. (2012). Detecting earnings management: A new approach. *Journal of Accounting Research*, 50(2).
- Dechow, P., Sloan, R., & Sweeney, A. (1995). Detecting Earnings Management. *The Accounting Review*, 70(2), 193–225.
- Finney, S. J., & DiStefano, C. (2006). Non-normal and Categorical Data in Structural Equation Modelling. 269–314. Greenwich, Connecticut: IAP.
- Francis, J., LaFond, R., Olsson, P., & Schipper, K. (2005). The market pricing of accruals quality. *Journal of Accounting and Economics*, 39, 295–327.
- Ge, W., & Kim, J.-B. (2014). Real earnings management and the cost of new corporate bonds. *Journal of Business Research*, 67, 641–647.
- Gutiérrez, A., & Rodríguez, M. (2017). A Review on the Multidimensional Analysis of Earnings Quality. Obtido de <https://dx.doi.org/10.2139/ssrn.2998134>
- Jones, J. (1991). Earnings management during import relief investigations. *Journal of Accounting Research*, 29(2), 193–228.
- Kothari, S. P., Leone, A., & Wasley, C. (2005). Performance matched discretionary accrual measures. *Journal of Accounting and Economics*, 39, 163–197.
- Larson, C., Sloan, R., & Giedt, J. Z. (2018). Defining, measuring and modeling accruals: A guide for researchers. Obtido de <http://dx.doi.org/10.2139/ssrn.2952601>
- Marôco, J. (2014). Análise de Equações Estruturais: Fundamentos teóricos, software & aplicações (2.^a). Pêro Pinheiro: Report Number.
- McNichols, M. (2002). Discussion of the quality of accruals and earnings: The role of accruals estimation errors. *The Accounting Review*, 77, 61–69.
- Mulaik, S. A., James, L. R., Van Alstine, J., Bennett, N., Lind, S., & Stilwell, C. D. (1989). Evaluation of Goodness-of-Fit Indices for Structural Equation Models. *Psychological Bulletin*, 105(3), 430–445.
- O'Brien, R. (2007). A Caution Regarding Rules of Thumb for Variance Inflation Factors. *Quality and Quantity*, 41(5), 673–690.
- Oliveira, S. (2017). A Demonstração de Fluxos de Caixa como instrumento estratégico de gestão (Dissertação de Mestrado em Gestão Empresarial). Instituto Politécnico de Coimbra, Coimbra.
- Rodrigues, J. (2015). SNC - Sistema de Normalização Contabilística Explicado (5.^a). Porto: Porto Editora.
- Roychowdhury, S. (2006). Earnings management through real activities manipulation. *Journal of Accounting and Economics*, 42, 335–370.
- Serapicos, A. (2016). A Relação entre o Desempenho, Remuneração do CEO e a Criação de Valor para o Acionista nas Empresas Cotadas na Euronext Lisbon: Abordagem com base na Teoria da Agência (Dissertação de Mestrado em Contabilidade e Finanças). Instituto Politécnico de Bragança, Bragança.
- Tanaka, J. S., & Huba, G. J. (1985). A fit index for covariance structure models under arbitrary GLS estimation. *British Journal of Mathematical and Statistical Psychology*, 38, 197–201.
- Wheaton, B. (1987). Assessment of fit in overidentified models with latent variables. *Sociological Methods and Research*, 16, 118–154.