



ARTUR FILIPE EWALD WUERGES

**DETECÇÃO DE FRAUDES CONTÁBEIS: É POSSÍVEL  
QUANTIFICAR OS CASOS NÃO-DESCOBERTOS?**

Dissertação de mestrado apresentada ao Curso de Pós-Graduação em Administração da Universidade Federal de Santa Catarina, como requisito parcial para a obtenção do título de Mestre em Administração.  
Orientador: Prof. Dr. José Alonso Borba

FLORIANÓPOLIS  
2010

Catálogo na fonte pela Biblioteca Universitária da  
Universidade Federal de Santa Catarina

W959d Wuerges, Artur Filipe Ewald

Detecção de fraudes contábeis [dissertação] : é possível quantificar os casos não-descobertos? / Artur Filipe Ewald Wuerges ; orientador, José Alonso Borba. - Florianópolis, SC, 2010.

117 p.: grafs., tabs.

Dissertação (mestrado) - Universidade Federal de Santa Catarina, Centro Sócio-Econômico. Programa de Pós-Graduação em Administração.

Inclui referências

1. Administração. 2. Fraude contábil. 3. Republicação. 4. Erros de classificação. I. Borba, Jose Alonso. II. Universidade Federal de Santa Catarina. Programa de Pós-Graduação em Administração. III. Título.

ARTUR FILIPE EWALD WUERGES

**DETECÇÃO DE FRAUDES CONTÁBEIS: É POSSÍVEL  
QUANTIFICAR OS CASOS NÃO-DESCOBERTOS?**

Esta dissertação foi julgada adequada para a obtenção do Grau de Mestre em Administração na área de concentração em Organizações, Sociedade e Desenvolvimento do Curso de Pós-Graduação em Administração da Universidade Federal de Santa Catarina e aprovada, em sua forma final, em 03 de março de 2010.

---

Prof. Dr. Maurício Serva  
Coordenador do Curso

Apresentada à Comissão Examinadora composta pelos professores:

---

Prof. Dr. José Alonso Borba  
Universidade Federal de Santa Catarina

---

Prof. Dr. Newton Carneiro Affonso da Costa Junior  
Universidade Federal de Santa Catarina

---

Prof. Dr. Antonio Lopo Martinez  
FUCAPE Business School

---

Prof. Dr. Fernando Dal-Ri Murcia  
Universidade Federal de Santa Catarina



T-stat looks too good.  
Use robust standard errors--  
significance gone.  
(Keisuke Hirano)



## RESUMO

As fraudes nas demonstrações financeiras prejudicam os acionistas e geram uma assimetria de informações que afeta a alocação de recursos no mercado de capitais. É possível identificar os determinantes da fraude através de um modelo econométrico de escolha binária (*probit* ou *logit*). Este trabalho demonstra que, caso esse modelo seja estimado sem levar em consideração a possibilidade de que algumas fraudes não tenham sido descobertas, o impacto estimado dos determinantes (variáveis independentes) poderá ser enviesado. Quando existem fraudes não descobertas ou empresas incorretamente acusadas de fraude, diz-se que existem erros de classificação na variável dependente. Nos casos em que esses erros são particularmente expressivos, como no Brasil, a estimação de um modelo de identificação de fraudes pode ser inviável. Em outros casos, como nos EUA, é possível reduzir o viés através de uma adaptação das funções utilizadas no modelo de escolha binária. É possível também estimar o percentual de fraudes não-descobertas através desse modelo adaptado. O modelo foi aplicado aos casos de fraude descobertos e processados pela *Securities and Exchange Commission* (divulgados através de *Accounting and Auditing Enforcement Releases*), nos EUA. Os resultados obtidos mostram que a probabilidade de ocorrência de fraude está negativamente correlacionada com o índice de liquidez corrente, com a variação do caixa (em relação ao ativo total) e com o ativo fixo (também em relação ao ativo total). Verificou-se, também, que empresas que mudaram de auditor ou que receberam um parecer de auditoria qualificado estão mais propensas à fraude. A probabilidade *a priori* de um caso de fraude não ser detectado foi estimada em 97,61%. Conclui-se que os resultados apontam para a necessidade de informações mais confiáveis a respeito de fraudes no mercado brasileiro – o que poderia viabilizar estudos similares no Brasil.

Palavras-chave: fraude contábil, AAER, republicação, erros de classificação.



## LISTA DE ABREVIATURAS E SIGLAS

AAER: *Accounting and Auditing Enforcement Release*  
ADR: *american depositary receipt*  
BBN: *bayesian belief network*  
CAR: *cumulative abnormal returns*, ou retornos anormais acumulados  
CEO: *chief executive office*, o principal executivo de uma empresa  
CF: constituição federal  
CVM: Comissão de Valores Mobiliários  
DRE: demonstração do resultado do exercício  
FCL: fluxo de caixa livre  
FCO: fluxo de caixa operacional  
FCPA: *Foreign Corrupt Practices Act*  
FDF: fraude nas demonstrações financeiras  
FNN: *fuzzy neural network*  
GAAP: princípios contábeis geralmente aceitos  
GLS: *generalized least squares*  
MHDIS: *multi-group hierarchical discrimination method*  
MQO: mínimos quadrados ordinários  
MV: máxima verossimilhança  
PNN: *probabilistic neural network*  
RNA: rede neural artificial  
ROA: *return on assets*, ou retorno sobre ativos.  
ROC: *receiving operating characteristic*  
SIC: *standard industrial classification*  
SEC: *Securities and Exchange Commission*  
SVM: *support vector machine*  
UTADIS: *Utilités Additives Discriminantes*  
WESML: *weighed exogenous sample maximum likelihood probit*  
WSJI: *Wall Street Journal Index*



## SUMÁRIO

1 INTRODUÇÃO .....	13
1.1 Objetivos .....	17
1.3 Justificativa .....	19
2 FUNDAMENTAÇÃO TEÓRICA .....	21
2.1 Demonstrações contábeis .....	21
2.1.1 Teoria da agência e demonstrações contábeis .....	21
2.1.2 Demonstrações contábeis no Brasil .....	24
2.1.3 A Comissão de Valores Mobiliários .....	25
2.1.4 Fraudes contábeis no Brasil .....	27
2.1.5 Fraudes contábeis nos EUA .....	31
2.2 O triângulo da fraude e seus indicadores .....	33
Fonte: adaptado de Turner et al. (2003) .....	34
2.2.1 Pressão e incentivos .....	34
2.2.1.1 Receitas, lucro e rentabilidade .....	35
2.2.1.2 Escore Z de Altman .....	37
2.2.1.3 Indicadores de liquidez .....	38
2.2.1.4 Alavancagem .....	39
2.2.1.5 Composição dos ativos .....	40
2.2.1.6 Remuneração variável .....	42
2.2.2 Oportunidade .....	43
2.2.2.1 Auditoria .....	44
2.2.3 Atitudes e racionalização .....	44
2.2.3.1 Accruals .....	45
2.3 Estudos similares .....	46
2.3.1 Estudos de eventos .....	47

2.3.2 Modelos <i>probit</i> e <i>logit</i> .....	48
2.3.3 Inteligência artificial .....	58
2.3.4 Estudos correlatos no Brasil.....	60
2.4 Modelos de escolha binária.....	63
2.4.1 Modelo <i>logit</i> .....	65
2.4.2 Modelo <i>probit</i> .....	66
2.4.3 Estimação da matriz de covariância.....	67
2.5 Erros de classificação.....	68
3 METODOLOGIA .....	73
3.1 Amostra (EUA).....	73
3.2 Amostra (Brasil).....	76
3.3 Formação do grupo de controle.....	78
3.4 Testes estatísticos.....	79
3.5 Estimação dos modelos com erros de classificação .....	81
4 RESULTADOS.....	83
4.1 Descrição das variáveis.....	84
4.2 Análise univariada.....	87
4.3 Modelo de Jones.....	92
4.4 Análise multivariada .....	94
4.4.1 Modelo <i>probit</i> , <i>matched pair</i> .....	94
4.4.3 Modelo com erros de classificação .....	99
5 CONCLUSÃO .....	105
REFERÊNCIAS BIBLIOGRÁFICAS.....	109
APÊNDICE A – Experimento de Monte Carlo.....	119
APÊNDICE B – Notação Matemática .....	125

## 1 INTRODUÇÃO

Em um discurso, Arthur Levitt (1999) – então *chairman* da SEC<sup>1</sup> – afirmou que a qualidade das informações é essencial para a eficiência dos mercados. Sem ela, a confiança dos investidores é afetada e a liquidez desaparece, pois analistas e investidores utilizam as informações divulgadas pelas empresas para tomar suas decisões. O livre mercado é alimentado por uma cultura de divulgação e livre acesso às informações que podem afetar o valor das empresas. Em condições ideais, o preço dos ativos (ações negociadas na bolsa de valores, por exemplo) é construído com base em todas as informações publicamente disponíveis. Quando isso ocorre, diz-se que o mercado é eficiente na forma semi-forte.

Nessa forma de eficiência de mercado, ainda pode ser possível obter ganhos anormais com base em informações privadas (*insider information*). Assim, algumas pessoas lucrariam às custas dos outros investidores, que apenas obterão essa informação após os preços já terem sido afetados pelos *insiders*. A possibilidade dessa assimetria informacional gera um custo, pois desperta desconfiança nos investidores. Eles não sabem se possuem todas as informações relevantes para precificar os ativos em que está investindo.

As fraudes nas demonstrações contábeis são uma espécie de assimetria informacional em que alguns poucos *insiders* sabem que as demonstrações financeiras não refletem a realidade, mas o mercado como um todo não sabe disso. Nesse contexto, a existência de fraudes contábeis abala a eficiência do mercado, cria uma assimetria de informações, distorce incentivos e – como consequência da desconfiança gerada – acarreta custos para todo o mercado.

As demonstrações financeiras têm um importante papel em diversas decisões de alocação de recursos. Quando um investidor escolhe comprar ações de uma empresa ou quando um banco rejeita um pedido de empréstimo, eles levam em consideração uma ampla gama de informações que têm à disposição: notícias, indicadores econômicos, cotações de *commodities*, e também os últimos balanços e demonstrações de resultados da empresa, etc.

A fraude contábil ocorre quando os gestores de uma empresa alteram os relatórios financeiros com o objetivo de fornecer aos acionistas informações distorcidas a respeito do desempenho econômico

---

<sup>1</sup> *Securities and Exchange Commission*, órgão regulamentador do mercado de ações nos EUA. Exerce um papel análogo ao da CVM (Comissão de Valores Mobiliários).

da empresa, ou então para influenciar resultados contratuais que dependem dos números contábeis – por exemplo, aumentar a remuneração variável dos executivos (HEALY; WAHLEN, 1999). Os gestores podem alterar as demonstrações de diversas formas: inflacionando ativos, receitas e lucro, ou diminuindo as despesas e o passivo (SPATHIS et al, 2002; TROY, 2003).

A importância do problema da fraude contábil deriva dos prejuízos que ela traz à eficiência na alocação dos recursos na economia. Pode-se afirmar que o sucesso dos mercados de capitais, em uma economia de mercado, depende da exatidão e da confiabilidade das demonstrações financeiras divulgadas pelas empresas negociadas em bolsa.

Ao maquiagem a situação financeira da empresa, os gestores acabam atraindo novos investidores e credores – mesmo que este não seja o objetivo principal da fraude. Como consequência, o capital é desviado para empresas menos eficientes, prejudicando o bom funcionamento do mercado.

As fraudes podem ser evitadas através de mecanismos de governança corporativa e de controle interno. Fora isso, uma das maneiras de minimizar as consequências das fraudes contábeis é identificar seus indícios, de forma a evitá-las ou detectá-las rapidamente assim que ocorrerem. Já foram propostos diversos modelos com a finalidade de estimar a probabilidade de ocorrência de fraudes. É possível utilizar várias estratégias de estimação, desde os modelos *probit* e *logit* (BEASLEY, 1996; ETTREDGE ET AL., 2008) até as ferramentas de inteligência artificial – tais como redes neurais e lógica nebulosa (FANNING e COGGER, 1998; OGUT ET AL., 2009; GAGANIS, 2009).

Normalmente, os executivos envolvidos em fraudes procuram ocultá-las – já que, no momento em que são descobertas, elas deixam de produzir os efeitos desejados. Além disso, é possível que as autoridades competentes, de forma intencional, deixem de investigar determinados casos de fraudes. Isto sugere que existem mais fraudes em andamento (além daquelas que chegam ao conhecimento do mercado), de tal forma que definir a variável dependente não é uma tarefa trivial. Existem erros de classificação: a variável dependente (ocorrência ou não de fraude) nem sempre assume o seu verdadeiro valor. O problema é sério o suficiente para merecer atenção especial: Hausman et al (1998) notaram que mesmo pequenos erros de classificação (2%) podem causar vieses significativos em grandes amostras, além de subestimar os desvios-padrões dos estimadores.

Em modelos paramétricos de escolha qualitativa (por exemplo, *probit* e *logit*), é possível corrigir o procedimento de estimação, de tal forma que sejam obtidos estimativas consistentes (isto é, que convergem assintoticamente ao valor real do parâmetro) mesmo na presença de erros de classificação. Este método foi introduzido por Hausman et al (1998).

Esta correção da função de máxima verossimilhança já foi aplicada a problemas em diversas áreas. Caudill e Mixon Jr. (2005) utilizaram o método na estimação da probabilidade de fraude em provas no ensino superior, chegando à conclusão de que 27% dos estudantes que afirmaram serem honestos na realidade não o eram.

Jensen et al. (2008) verificaram erros na concessão de patentes. Este é um caso diferente do anterior, pois são dois os tipos de erros que interessam: patentes incorretamente concedidas e incorretamente negadas. A probabilidade do primeiro erro é de 9,8%; a do segundo erro é de 6,1%.

Em uma situação mais próxima da analisada neste trabalho, Artís, Ayuso e Guillén (2002) criaram um modelo de previsão de fraudes em seguros de automóveis. Neste caso, a probabilidade de que um sinistro seja erroneamente classificado como válido é de 4,7% (estatisticamente significativo ao nível de 5%).

Os trabalhos sobre fraude em provas e seguros apresentam pontos em comum com o estudo sobre fraudes contábeis. Em todos eles, tenta-se desenvolver um modelo econométrico para identificar a pessoa ou empresa que cometeu um ato ilícito ou moralmente inaceitável<sup>2</sup>. Nas fraudes em seguros e nas demonstrações financeiras, todos os envolvidos desejam ocultá-las; no caso das provas, algumas pessoas podem revelá-la voluntariamente ao pesquisador (CAUDILL e MIXON JR., 2005). Devido a essas semelhanças, é possível aplicar essa metodologia a modelos econométricos para identificação de fraudes nas demonstrações financeiras.

Os estudos citados mostram que o erro de classificação da variável dependente frequentemente é um problema real em aplicações empíricas. É importante estimar estes erros de classificação por três motivos: em primeiro lugar, a própria probabilidade de erro pode ser importante. No caso específico de fraudes contábeis, é relevante saber o

---

<sup>2</sup> Mais exatamente, busca-se estimar a probabilidade de que um determinado indivíduo tenha cometido o ato ilícito.

grau de impunidade das práticas fraudulentas. Isto permite acompanhar a eficácia das políticas de repressão e prevenção à fraude.

Em segundo lugar, a estimação dos erros de classificação permite previsões mais precisas. Quando o modelo é utilizado em uma seguradora de automóveis (como no artigo já citado), por exemplo, a inclusão dos erros de classificação aumenta a sua confiabilidade, evitando falsos negativos (erros tipo I).

Por fim, ignorar os erros de classificação tem o efeito de enviesar as estatísticas  $z$  dos modelos, como pode ser demonstrado através de simulações de Monte Carlo (Apêndice A). Este problema é importante, pois reconhecê-lo significa reconhecer também que muitos dos testes de hipóteses feitos com o uso de modelos que não incluem erros de classificação podem simplesmente não ser válidos.

Esta dissertação busca suprir essa lacuna, desenvolvendo modelos empíricos para a detecção de fraudes contábeis a partir de dados publicamente disponíveis, com a inclusão de erros de classificação. Com isso, poderá identificar fatores que contribuem para a ocorrência da fraude. Também será apresentada uma estimativa para a probabilidade de que um caso de fraude não seja descoberto.

No Brasil, tem-se dificuldades adicionais pelo fato de não terem sido encontrados trabalhos que utilizem modelos econométricos para detecção de fraudes. Isso pode ser decorrente, em parte, da falta de informações publicamente disponíveis sobre fraudes. A melhor *proxy* existente são as republicações ordenadas pela CVM<sup>3</sup>, mas ela é particularmente suscetível a erros de classificação. Existem, inclusive, casos de republicações que não são necessariamente consequência de fraude. Por isso, nesse caso, deve-se investigar maneiras de construir a variável dependente, e a própria viabilidade da estimação de um modelo de identificação de fraudes no Brasil.

Em trabalhos acadêmicos que propõem modelos de detecção ou previsão de fraudes contábeis nos EUA, normalmente utiliza-se os *Accounting and Auditing Enforcement Releases*<sup>4</sup> (AAERs) publicados pela SEC como variável dependente. O uso destes *releases* tem a vantagem de permitir que os estudos sejam baseados em informações publicamente disponíveis. Por outro lado, a SEC não é capaz de detectar

---

<sup>3</sup> Comissão de Valores Mobiliários – órgão que exerce papel semelhante ao da SEC, no Brasil.

<sup>4</sup> Esses *releases* consistem na divulgação de informações referentes a um processo administrativo ou judicial aberto pela SEC contra uma empresa ou pessoa, referente a uma violação contábil ou de auditoria.

todos os casos de fraudes que ocorrem no mercado – na verdade, a Comissão possui um orçamento limitado, e por isso concentra-se em casos de maior repercussão ou em que tenha maior chance de vitória nos tribunais. Por isso, pode-se levantar a hipótese de que existem erros de classificação substanciais em variáveis dependentes construídas a partir de AAERs. Esta dissertação surgiu a partir da percepção de que isso pode influenciar os resultados obtidos na literatura sobre fraudes. O problema de pesquisa é: qual o impacto dos erros de classificação na variável dependente em modelos econométricos utilizados para identificar a existência de fraude nas demonstrações financeiras?

## 1.1 Objetivos

O objetivo geral é quantificar os erros de classificação na variável dependente em modelos empíricos utilizados para identificar a existência de fraude nas demonstrações financeiras.

Os objetivos específicos são:

a) Verificar, através de uma análise univariada, quais das variáveis identificadas na literatura são diferentes nas empresas acusadas de fraude.

Esse objetivo é alcançado através de testes de diferença de medianas (*rank-sum* de Wilcoxon). Ou seja, para cada variável, será verificado se os dois grupos (empresas acusadas de fraude e grupo de controle) possuem medianas iguais ou diferentes. Deseja-se identificar variáveis que estão de alguma forma relacionadas com a presença de fraude.

b) Demonstrar a importância dos erros de classificação em modelos de detecção de fraudes, através de um experimento de Monte Carlo.

Esse objetivo é alcançado através de três testes de hipóteses. Em primeiro lugar, como esse experimento será realizado com dados gerados artificialmente, tanto a variável dependente real quanto a observada são conhecidas. Sendo  $\hat{\beta}_y$  o estimador de  $\beta$  obtido quando se utiliza a verdadeira variável no lado esquerdo, e  $\hat{\beta}_y$  o estimador obtido quando se utiliza a variável observada, deseja-se comprovar que estes estimadores são diferentes – isto é, o estimador de máxima verossimilhança (MV) é inconsistente na presença de erros de classificação:

$$H_0: \hat{\beta}_y = \hat{\beta}_{\bar{y}}$$

$$H_1: \hat{\beta}_y \neq \hat{\beta}_{\bar{y}}$$

O segundo teste de hipóteses tem como objetivo verificar se o estimador com erros de classificação proposto por Hausman (1998), aqui denotado por  $\gamma_{\bar{y}}$ , é igual ao valor obtido ao se utilizar um estimador tradicional com a variável dependente real:

$$H_0: \gamma_{\bar{y}} = \hat{\beta}_y$$

$$H_1: \gamma_{\bar{y}} \neq \hat{\beta}_y$$

Por fim, sendo  $\alpha_1$  a verdadeira proporção deste tipo de erro e  $\hat{\alpha}_1$  a estimativa deste parâmetro, busca-se verificar se as estimativas obtidas são consistentes.

$$H_0: \hat{\alpha}_1 = \alpha_1$$

$$H_1: \hat{\alpha}_1 \neq \alpha_1$$

A não-rejeição da hipótese nula, nestes dois últimos teste, sugere que o estimador de Hausman é viável em um modelo de detecção de fraudes – mesmo com erros de classificação. Feitos estes testes, pode-se passar para a análise dos dados reais.

c) Estimar um modelo econométrico de escolha binária para detecção de fraudes;

Aqui, deseja-se verificar se a matriz  $\mathbf{X}$ , composta pelas variáveis independentes escolhidas, é capaz de explicar a ocorrência de fraude contábil:

$$H_0: \hat{\beta} = 0$$

$$H_1: \hat{\beta} \neq 0$$

Esse teste é importante porque a estimação de um modelo só será bem-sucedida caso a  $H_0$  seja rejeitada em um teste de razão de verossimilhança ou em um teste de Wald. Caso contrário, não será possível afirmar que as variáveis independentes estão relacionadas com a ocorrência de fraude.

d) Estimar o percentual de casos de fraude não-descobertos

De acordo com Hausman (2001), a estimação do erro de classificação pode funcionar como um teste para verificar se estes erros afetam o modelo em questão. Deseja-se portanto testar a existência ou não de erros de classificação:

$$H_1: \alpha_1 > 0$$

$$H_0: \alpha_1 \leq 0$$

Esse objetivo só poderá ser alcançado após os outros objetivos específicos terem sido cumpridos, pois a estimação dos erros de classificação deve ser feita através de um modelo que contenha variáveis relacionadas com a fraude (objetivos *a* e *c*). Além disso, também é importante verificar se o método utilizado na estimação desses erros é confiável (objetivo *b*).

### 1.3 Justificativa

A importância deste trabalho pode ser observada em alguns de seus aspectos. Primeiro, as fraudes contábeis são um problema real e importante para as empresas brasileiras e estrangeiras, pois geram assimetria de informações e podem contribuir para decisões de investimento equivocadas – o que pode até mesmo acarretar ações legais contra a empresa (BARBER ET AL., 1993). Em segundo lugar, as técnicas econométricas utilizadas não são ainda muito usuais, de tal forma que o trabalho também tem o objetivo de avançar no estudo dos erros de classificação em modelos de escolha binária.

Na literatura internacional não foi encontrado artigo sobre fraudes contábeis que utilizasse a metodologia de estimação dos erros de classificação proposta por Hausman et al. (1998). Portanto, uma contribuição desta dissertação é a introdução desse modelo em estudos empíricos sobre fraudes. O modelo proposto é mais robusto e apresenta resultados em parte diferentes daqueles apresentados por estudos similares. Espera-se que os resultados estimulem outros estudos similares, dada a importância do viés causado pelos erros de classificação nos modelos até então utilizados.

É importante ressaltar que existem *working papers* que utilizam uma metodologia similar na identificação de fraudes (WANG, 2004 e 2008). O modelo de Wang estima a probabilidade de erro de

classificação *condicional* a determinadas variáveis que influenciam a detecção da fraude. O modelo aqui proposto estima o erro de classificação como um coeficiente – sendo, portanto, uma probabilidade *incondicional*. Esta é uma limitação da proposta desta dissertação – mas, por outro lado, a probabilidade *a priori* de não-detecção de uma fraude também é relevante para a pesquisa.

Este trabalho também poderá permitir que no futuro as fraudes no Brasil sejam melhor estudadas. O grande entrave para a pesquisa sobre demonstrações financeiras fraudulentas, no Brasil, é a inexistência de informações precisas sobre a ocorrência ou não de fraude. Uma das melhores *proxies* disponíveis são as republicações ordenadas pela CVM. Neste caso, porém, os erros de classificação são inevitáveis, pois muitas republicações não afirmam categoricamente que as demonstrações foram manipuladas. Há portanto uma dupla zona de incerteza: existem republicações que podem ser resultado de erros honestos, e certamente existem muitas empresas que deliberadamente manipularam seus resultados e não foram obrigadas a republicar suas demonstrações. O modelo proposto por Hausman et al. (1998) permite que ambos os erros sejam estimados, desde que certas condições sejam satisfeitas. Isso permite o estudo de fraudes em situações em que poucas informações estão disponíveis, como é o caso do Brasil. Por isso, este trabalho aplica a metodologia criada por Hausman et al. ao estudo de fraudes nas demonstrações financeiras.

Portanto, ao avançar nas possibilidades metodológicas aplicáveis ao estudo sobre fraudes contábeis, esta dissertação também abre caminho para que no futuro as fraudes sejam estudadas em ambientes onde existem menos informações disponíveis, como o Brasil.

## 2 FUNDAMENTAÇÃO TEÓRICA

### 2.1 Demonstrações contábeis

Para compreender as fraudes contábeis, inclusive suas causas e efeitos, é importante primeiro entender as características e a importância da divulgação de relatórios financeiros, sob uma perspectiva teórica. Isso é feito com o auxílio da teoria da agência, na seção 2.1.1.

No Brasil, as demonstrações contábeis são regulamentadas pela Lei n. 6.404/76, mais conhecida como Lei das Sociedades por Ações. Para saber o que é ilegal, é necessário saber o que essa lei proíbe. Por isso, a seção 2.1.2 analisa brevemente o capítulo XV dessa lei, que trata do exercício social e das demonstrações financeiras.

Aproveitando o estudo da legislação brasileira, a seção 2.1.3 explica as responsabilidades atribuídas à CVM pela Lei n. 6.385/76 e os poderes que esta entidade possui para coibir as fraudes.

Com isso, terão sido abordadas as determinações legais referentes ao *disclosure* e o funcionamento geral da regulamentação do mercado. Pode-se então partir para o tema deste estudo, que é um dos casos especiais de descumprimento das determinações legais (e também do Código Penal). Para isso, constrói-se uma definição de fraude, com base na literatura existente e também à luz da Lei n. 6.404 e do Código Penal. É disso que trata a seção 2.1.4.

A literatura existente sobre fraudes contábeis é, em grande parte, voltada para os mercados de capitais norte-americanos. Por esse motivo, a compreensão dos modelos já utilizados em estudos similares depende do entendimento dos *Accounting and Auditing Enforcement Releases* publicados pela SEC, usualmente utilizados para construir a variável dependente nestes artigos. Por isso, a seção 2.5 da fundamentação teórica será dedicada à fraude contábil nos EUA, em especial aos AAERs.

#### 2.1.1 Teoria da agência e demonstrações contábeis

Nas modernas corporações, sociedades anônimas profissionalmente administradas, com diversos acionistas, são estabelecidos relacionamentos de agência – que, na definição de Jensen e Meckling (1976), são contratos em que uma ou mais pessoas (os principais) entregam a outra pessoa (o agente) alguma tarefa envolvendo tomada de

decisões. São justamente estes contratos de agência que permitem a dissociação entre propriedade e administração de uma empresa.

Se ambas as partes agirem de forma racional, é esperado que as decisões do agente nem sempre maximizem a utilidade do principal. Há um verdadeiro desalinhamento de interesses. Um exemplo disso é a questão do comportamento em relação ao risco: enquanto o principal é teoricamente neutro ao risco (pois é capaz de diversificar seus investimentos), o agente é avesso ao risco, já que possui apenas um emprego e não deseja se arriscar a perdê-lo (EISENHARDT, 1989).

A teoria da agência busca compreender e resolver este e outros problemas que surgem devido às relações entre as duas partes com interesses potencialmente conflitantes. De fato, existem certas ações que podem ajudar a alinhar os interesses do agente com os do principal. Uma das maneiras de minimizar o problema da agência é desenvolver sistemas de informação que permitam ao principal saber o que o agente realmente está fazendo – isto é, monitorá-lo. Com isso, o agente terá maior probabilidade de agir de acordo com os interesses do principal (EISENHARDT, 1989; JENSEN e MECKLING, 1976). Um dos elementos desse sistema de monitoramento é a divulgação de demonstrações contábeis (*disclosure*).

Percebe-se, com base no exposto, que o relacionamento de agência acarreta custos para as partes envolvidas, adequadamente chamados de *custos de agência*. As despesas envolvidas com a criação de sistemas de monitoramento são um deles.

Outra espécie de custo de agência são os *bonding costs*, que são os recursos utilizados pelo próprio agente com o objetivo de garantir ao principal que ele (o agente) não tomará decisões prejudiciais aos interesses dos proprietários da empresa. É o caso, por exemplo, de contratos que limitam o poder decisório do executivo.

Existe outra espécie de custo de agência, que ocorre quando há uma divergência entre as decisões do agente e as decisões que maximizariam a utilidade<sup>5</sup> do principal. A diferença entre a utilidade que poderia ser obtida e aquela efetivamente alcançada é conhecida como *perda residual*. Assim, se o executivo decide viajar na primeira classe com as despesas pagas pela companhia (mas viajaria na classe executiva se fosse o dono da empresa), a diferença entre o preço das duas passagens é uma perda residual, efetivamente diminuindo o valor da empresa e a utilidade dos acionistas.

---

<sup>5</sup> Jensen e Meckling (1976) usam a expressão *welfare*, aqui traduzida como *utilidade*.

Os acionistas minoritários sabem que os interesses dos acionistas majoritários (e administradores) divergem dos seus; por isso, o preço que eles irão pagar pelas ações reflete as perdas residuais e o custo de monitoramento. Quem efetivamente paga por estes custos são os proprietários da empresa, que serão obrigados a vender as ações por um preço mais baixo ao abrir capital (JENSEN e MECKLING, 1976).

Em resumo, o desalinhamento de interesses entre agente e principal acarretam custos que diminuem o valor da empresa, onerando o principal. Por isso, até certo ponto, o proprietário irá estimular a transparência da empresa – por exemplo, adotando boas práticas de governança corporativa. A lógica é que, quando um investimento em governança corporativa, custando  $x$ , diminuir os custos de agência em um valor maior do que  $x$ , ele será implementado pela empresa. Este é um dos motivos pelos quais algumas empresas aderem ao Novo Mercado da Bovespa, comprometendo-se a fornecer mais informações contábeis do que o exigido pela legislação. Pode-se perceber que as demonstrações financeiras, longe de serem uma obrigação legal sem retorno financeiro, são uma ferramenta para diminuir os custos de agência, aumentando o valor total da empresa (JENSEN e MECKLING, 1976).

O *disclosure* não é benéfico apenas para empresas com capital pulverizado. Assim como os acionistas minoritários, os credores da empresa também têm interesse em monitorá-la, de forma a evitar atitudes que diminuam o valor da dívida (por exemplo, contrair novas dívidas ou distribuir dividendos acima de um determinado limite). O custo do monitoramento recai – mesmo que de forma indireta – sobre o principal acionista (ou proprietário) da empresa, de tal forma que administradores devem agir para que estes custos sejam minimizados. Uma das formas de diminuí-los é fornecer voluntariamente os relatórios contábeis desejados pelos credores, contratando um auditor independente para verificar a exatidão destas informações. É por esse motivo que o *disclosure* diminui o custo de capital de terceiros (JENSEN e MECKLING, 1976).

Se houver a possibilidade de que essas informações voluntariamente fornecidas pelas empresas sejam falsas – isto é, fraudulentas – então os benefícios do *disclosure* voluntário serão menores do que em uma situação em que não houvesse nenhuma possibilidade de fraude. Basta verificar que, se as demonstrações financeiras fossem *sempre* fraudulentas, os credores optariam por assumir por completo as atividades de monitoramento e controle,

aumentando o custo de capital de terceiros. Deduz-se então que, em uma situação intermediária – *alguma possibilidade* de fraude – os custos seriam maiores do que em uma situação perfeita, porém não necessariamente altos o suficiente para invalidar a divulgação voluntária das informações relevantes.

Opera-se, através da fraude, uma transferência de utilidade que beneficia as empresas desonestas, em prejuízo do conjunto de empresas honestas – que veem seus custos de capital de terceiros aumentar de forma diretamente proporcional ao risco de fraude. É esta constatação que motiva o combate às violações das demonstrações contábeis. Ao punir os administradores envolvidos nestas atividades, as agências regulamentadoras e o sistema legal contribuem para diminuir os custos dos credores (desde que, naturalmente, o custo marginal da atividade regulamentadora seja menor do que o benefício marginal dos credores), estimulando a atividade econômica e trazendo benefícios à sociedade como um todo.

### 2.1.2 Demonstrações contábeis no Brasil

O fato da publicação de determinadas demonstrações financeiras ser exigida na forma de lei não exclui as vantagens decorrentes da diminuição dos custos de monitoramento. A Lei n. 6.404, art. 176, incisos I a V, explicita as demonstrações que devem ser publicadas, exprimindo “com clareza a situação do patrimônio da companhia e as mutações ocorridas no exercício”. São elas:

- a) balanço patrimonial;
- b) demonstração das mutações do patrimônio líquido;
- c) demonstração do resultado do exercício (DRE);
- d) demonstração dos fluxos de caixa; e
- e) se companhia aberta, demonstração do valor adicionado.

A mesma norma dispõe sobre a obrigatoriedade da análise das demonstrações financeiras por um auditor independente:

As demonstrações financeiras das companhias abertas observarão, ainda, as normas expedidas pela Comissão de Valores Mobiliários e serão obrigatoriamente submetidas a auditoria por auditores independentes nela registrados. (Lei n. 6.404, art. 177, § 3º)

Em seguida, o mesmo artigo estabelece limites à atuação normativa desta Comissão:

As normas expedidas pela Comissão de Valores Mobiliários a que se refere o § 3º deste artigo deverão ser elaboradas em consonância com os padrões internacionais de contabilidade adotados nos principais mercados de valores mobiliários. (Lei n. 6.404, art. 177, § 5º)

Este último dispositivo é recente, tendo sido introduzido pela Lei n. 11.638, de 28 de dezembro de 2007.

Fica claro, pelo exame da Lei, que a autoridade competente para regulamentar e fiscalizar – dentro dos limites impostos – as demonstrações financeiras das empresas abertas é a Comissão de Valores Mobiliários (CVM).

### 2.1.3 A Comissão de Valores Mobiliários

A Comissão de Valores Mobiliários é uma entidade autárquica vinculada ao Ministério da Fazenda, dotada de autoridade administrativa independente e (assim como todas as autarquias) ausência de subordinação hierárquica. Foi criada pela Lei n. 6.385, de 7 de dezembro de 1976, e suas atribuições são estabelecidas no art. 4º. Entre elas estão:

“III – assegurar o funcionamento eficiente e regular dos mercados da bolsa e de balcão;  
IV – proteger os titulares de valores mobiliários e os investidores do mercado contra: (...)  
b) atos ilegais de administradores e acionistas controladores de companhias abertas;  
V – evitar ou coibir modalidades de fraude ou manipulação destinadas a criar condições artificiais de demanda, oferta ou preço de valores mobiliários negociados no mercado;  
IV – assegurar o acesso público a informações sobre valores mobiliários negociados e as companhias que os tenham emitido.”

Em relação a esse último item, a atribuição da CVM não se esgota no simples acesso público às informações relevantes. É imprescindível que as demonstrações financeiras sejam uniformes e

confiáveis, o que justifica a normatização e a exigência de submissão a auditores independentes.

A atribuição de impor normas pressupõe os poderes necessários para exigir o efetivo cumprimento delas. É disso que trata o art. 9º:

A Comissão de Valores Mobiliários [...], poderá:

**IV – determinar às companhias abertas que republique, com correções ou aditamentos, demonstrações financeiras, relatórios ou informações divulgadas;**

V – apurar, mediante processo administrativo, atos ilegais e práticas não equitativas de administradores, membros do conselho fiscal e acionistas de companhias abertas, dos intermediários e dos demais participantes do mercado;

VI – aplicar aos autores das infrações indicadas no inciso anterior as penalidades previstas no Art. 11, sem prejuízo da responsabilidade civil ou penal. (Lei n. 6.385, art. 9º)

A interpretação deste artigo deixa claro que a republicação ordenada pela CVM pode ser, mas não necessariamente é, decorrente da descoberta de fraude nas demonstrações financeiras. O inciso V indica que a CVM poderá a investigar ilegalidades – entre as quais se incluem as fraudes. O legislador utilizou a palavra *poderá* ao invés de *deverá*, indicando que a abertura de processo administrativo é um ato discricionário da CVM. Esta opção se deve ao desejo de permitir à Comissão concentrar seus esforços nos casos de maior vulto, como confirma o seguinte dispositivo da mesma lei: § 4º do mesmo artigo:

Na apuração de infrações da legislação do mercado de valores mobiliários, a Comissão deverá dar prioridade às infrações de natureza grave, cuja apenação proporcione maior efeito educativo e preventivo para os participantes do mercado. (Lei n. 6.385, art. 9º, § 4º)

As penalidades aplicáveis pela CVM, previstas no art. 11 da Lei n. 6.385 (e aplicáveis aos infratores desta mesma Lei), incluem advertência e multa (que costuma ser de R\$ 1.000 por dia). Nos casos graves, há suspensão de determinados direitos das pessoas envolvidas (por exemplo, suspensão do exercício do cargo de administrador ou conselheiro fiscal de companhia aberta).

Buscando cumprir a determinação legal de fiscalizar as informações divulgadas pelas companhias abertas, o Presidente da CVM publicou a Deliberação 338, de 2 de maio de 2001, autorizando o Superintendente de Relações com Empresas a tornar públicas as determinações de refazimento ou republicação. Esta Deliberação, em conjunto com os poderes delegados pela Lei n. 6.385, criam a possibilidade de acompanhamento e controle da qualidade das demonstrações contábeis das empresas abertas brasileiras, especialmente no que concerne a fraudes.

Para o exercício desta responsabilidade de acompanhamento e controle do mercado de valores mobiliários, é imprescindível que a CVM seja independente e livre de influências políticas que minem a adoção de critérios técnicos em suas decisões. Por isso, juridicamente, a CVM diferencia-se por ser uma entidade autárquica em regime especial. Isso significa que possui determinadas garantias legais à sua autonomia, não extensíveis a outras autarquias.

Uma destas garantias está expressa no art. 6º, que no caput condiciona a nomeação dos presidentes e diretores da CVM à aprovação do Senado Federal. O § 2º deste mesmo artigo confere estabilidade a estes funcionários: “os dirigentes da Comissão somente perderão o mandato em virtude de renúncia, de condenação judicial transitada em julgado ou de processo administrativo disciplinar”. O legislador<sup>6</sup>, neste artigo, procurou evitar que a CVM fosse utilizada como ferramenta política, mantendo a natureza técnica e independente que uma agência reguladora deve ter.

#### 2.1.4 Fraudes contábeis no Brasil

Independentemente do significado que se queira atribuir à palavra fraude, só será punido aquilo que violar o que está disposto na lei – como consequência do princípio da legalidade: “ninguém será obrigado a fazer ou deixar de fazer alguma coisa senão em virtude de lei” (CF/88, art. 5º, inciso II). Por isso, a definição de fraude adotada neste estudo será construída com base naquilo que a lei proíbe. As definições de outros autores, porém, serão úteis para diferenciar atos ilegais que são fraudes daqueles que não são fraudes.

---

<sup>6</sup> Na verdade, estas garantias foram introduzidas pela MP 8/2001, que posteriormente foi convertida na Lei n. 10.411, de 26 de fevereiro de 2002. De acordo com a redação original, os dirigentes da CVM eram demissíveis *ad nutum*, ou seja, de acordo com a conveniência do Presidente da República.

Existem dois documentos legais que interessam ao estudo das fraudes. O primeiro deles é o Código Penal (Decreto-Lei n. 2.848), o segundo é a Lei n. 6.385, que determina condutas puníveis e as punições aplicáveis pela CVM.

O Código Penal prevê diversas modalidades de fraude – nem todas relacionadas às demonstrações financeiras. Existem, por exemplo, fraudes para recebimento de seguro (art. 171, § 2º, V) e no comércio (art. 175). O que convencionou-se chamar de fraude contábil está incluso no art. 177, § 1º, que sujeita à pena de um a quatro anos de reclusão, além de multa, o:

“I - diretor, o gerente ou o fiscal de sociedade por ações, que, em prospecto, relatório, parecer, balanço ou comunicação ao público ou à assembléia, faz afirmação falsa sobre as condições econômicas da sociedade, ou oculta fraudulentamente, no todo ou em parte, fato a elas relativo;

II – o diretor, o gerente ou fiscal que promove, por qualquer artifício, falsa cotação das ações ou de outros títulos da sociedade; [...]

VI – o diretor ou o gerente que, na falta de balanço, em desacordo com este, ou mediante balanço falso, distribui lucros ou dividendos fictícios.”

O primeiro inciso trata justamente daquilo que pode ser chamado de *violação das demonstrações financeiras* ou fraude nas demonstrações financeiras<sup>7</sup> (FDF). Caso estas informações falsas sejam fornecidas com o objetivo de valorizar as ações da empresa na bolsa, o inciso II também será aplicável. Evidentemente, existem outras maneiras de “promover falsa cotação das ações” de uma empresa, que nem sempre caracterizam uma fraude contábil. Da mesma forma, o crime do inciso VI pode ou não ser cometido mediante fraude contábil.

O inciso I trata de um *meio* que pode ser utilizado para diversos fins. Trata-se de um crime de mera conduta, ou formal – ele ocorre mesmo que ninguém seja efetivamente prejudicado. Os incisos II e VI especificam *fins* que podem ou não ser alcançados por meio das ações do inciso I. Punir a simples afirmação falsa (ou omissão) é a maneira que o legislador encontrou para evitar que os agentes prejudicassem o acionista em situações não abrangidas pelos incisos II e VI.

---

<sup>7</sup> Esta expressão é equivalente a *financial statement fraud*, frequentemente utilizada na literatura internacional.

A punibilidade da fraude contábil, portanto, independe dos fins desejados pelo agente. É necessário apenas que haja dolo, isto é, intenção de agir conforme o inciso I. Isto significa que o erro involuntário, mesmo que decorrente de imperícia ou negligência, não é crime. Nestes casos, cabem apenas as punições aplicáveis pela CVM (e as decorrentes de um eventual processo na esfera civil).

O art. 9º da Lei n. 6.835 prevê a abertura de processo administrativo no caso de atos ilegais e práticas não equitativas de administradores, membros do conselho fiscal e acionistas de companhias abertas. Este mesmo artigo não especifica quais são estas situações que ensejam processo administrativo, mas presume-se que sejam quaisquer atos ilegais de competência da CVM, não necessariamente previstos na Lei n. 6.835. Assim, no caso de violações das disposições da Lei n. 6.404 referentes às demonstrações financeiras (capítulo XV), mesmo que involuntárias, cabe à CVM fiscalizar e punir.

Percebe-se então que existem duas espécies diferentes de situações combatidas pela legislação: há o erro e a fraude; ambas são espécies de violação nas demonstrações contábeis. A princípio, todas as violações são de competência da CVM – mesmo as involuntárias (erro). Caso se comprove o dolo, ocorre a situação específica de *fraude contábil*, que é de competência tanto da CVM como do Ministério Público (justiça criminal).

Na prática, esta distinção implica que as republicações ordenadas pela CVM podem envolver tanto casos de fraude quanto erros não-intencionais. Isto dificulta o estudo de fraudes, que são apenas os casos de violação intencional.

Apesar de não fazer referência à legislação brasileira, esta distinção já era feita por Murcia (2007, p. 23), referindo-se aos diversos tipos de fraudes corporativas: “ao contrário do ‘erro’, que se trata de um ato não-intencional, a fraude refere-se ao ato intencional de tirar benefício próprio de determinada situação”. Esta definição está correta, com a ressalva de que a *fraude contábil* é perfeitamente caracterizada mesmo que ninguém seja efetivamente beneficiado.

**Quadro 1: principais diferenças entre gerenciamento de resultados, erro e fraude contábil**

<b>Gerenciamento de Resultados</b>		
<b>Métodos</b>	<i>Accruals</i> discricionários; Escolha de métodos contábeis; Decisões e atos concretos.	
<b>Motivos</b>	Evitar reportar prejuízo; Diminuir a volatilidade dos retornos; Piorar os resultados atuais para reportar lucro no futuro.	
<b>Exemplos</b>	Evitar ou reduzir o reconhecimento de provisões; Reduzir as cotas de depreciação e amortização; Reconhecimento de receitas durante a produção (MARTINEZ, 2001).	
<b>Punição / consequências legais</b>	Republicação.	
<b>Erro</b>		
<b>Métodos</b>	Não é intencional.	
<b>Motivos</b>	Imperícia e negligência.	
<b>Exemplos</b>	Esclarecimentos insuficientes para a compreensão completa das demonstrações financeiras; Uso de métodos inadequados para avaliação de ativos.	
<b>Punição / consequências legais</b>	<b>CVM:</b> Republicação; Em caso de atraso na republicação, é aplicada multa de R\$1.000/dia (sem prejuízo de outras sanções administrativas).	
<b>Fraude Contábil</b>		
<b>Métodos</b>	Omissão e falsificação.	
<b>Motivos</b>	Manter os investidores satisfeitos e atrair novos acionistas; Obter financiamento externo; Evitar penalidades contratuais (violação de <i>covenants</i> ); Garantir o bônus dos executivos.	
<b>Exemplos</b>	Registrar venda fictícia; Antecipar (documentalmente) a data de realização das vendas; Superestimar o estoque pelo registro de inventário fictício (MARTINEZ, 2001).	
<b>Punição / consequências legais</b>	<b>CVM:</b> Republicação; Em caso de atraso na republicação, é aplicada multa de R\$1.000/dia.	<b>Justiça Criminal:</b> Um a quatro anos de reclusão; Multa.

A construção desta definição, basicamente jurídica, tem a vantagem de evitar (no caso brasileiro) uma polêmica comum na literatura – a distinção entre *fraude contábil* e *gerenciamento de*

*resultados (earnings management)*. A diferença é que, enquanto a fraude contraria a legislação (propositalmente), o gerenciamento de resultados não é punível pela CVM e muito menos pelo poder judiciário. O gerenciamento é realizado dentro das limitações da lei. Mais exatamente, ele

(...) caracteriza-se fundamentalmente como alteração proposital dos resultados contábeis (intencional), visando alcançar, atender motivação particular. A gestão “maneja” artificialmente os resultados com propósitos bem definidos, que não são os de expressar a realidade latente no negócio (MARTINEZ, 2001)

O gerenciamento de resultados opera dentro das normas contábeis, mas é uma prática também danosa à qualidade das informações contábeis, e como tal deve ser descoberto, compreendido e evitado. Assim como a fraude, o gerenciamento de resultados traz prejuízos à eficiência na alocação de recursos entre as empresas (MARTINEZ, 2001).

Pode-se adicionar uma terceira categoria de violação nas demonstrações financeiras, formada pelos erros não-propositais que violam a legislação, e que motivam uma republicação ordenada pela CVM. O Quadro 1 mostra as principais diferenças entre estes três tipos de problemas nas demonstrações financeiras.

Outra distinção importante é que o gerenciamento normalmente faz uso de *accruals* discricionários para alterar os resultados ou reduzir sua volatilidade (BARTON, 2001), enquanto a fraude altera os fluxos de caixa apresentados nos demonstrativos financeiros e é decorrência de omissão e falsificação.

### 2.1.5 Fraudes contábeis nos EUA

Até 1982, a SEC publicava *Accounting Series Releases*, que podiam anunciar mudanças nas regras contábeis ou relatar ações contra auditores independentes ou internos. A partir de 1982, as investigações de violações das normas contábeis passaram a ser divulgadas em um novo tipo de documento, chamado *Accounting and Auditing Enforcement Release* (FEROZ et al, 1991).

Estes *releases* (AAERs) não se referem apenas a casos de fraudes. Eles podem também conter situações em que o erro é não-intencional ou decorrente de interpretações diferentes das normas

contábeis, ou então casos de corrupção: o *release* número 3.021 (de 28 de julho de 2009), por exemplo, determinava o fim de práticas de corrupção envolvendo executivos da Avery China (uma subsidiária da Avery Dennison) e oficiais do governo chinês. Por isso que, para este trabalho, deve-se identificar os AAERs relevantes, que envolvem os *materially false and misleading financial statements*, isto é, demonstrações materialmente falsas e enganosas.

A SEC não investiga formalmente todos os casos suspeitos de fraude. Investigações são caras, e portanto a comissão escolhe as empresas que serão investigadas de acordo com a probabilidade de sucesso e o efeito intimidatório que a ação teria sobre as outras empresas. Os casos de fraude que a SEC deixa de investigar e punir dão origem a erros de classificação, caso se considere os AAERs como sendo a variável dependente de um modelo de detecção de fraudes (*probit* ou *logit*).

Feroz et al (1991) também verificaram as contas que costumavam ser adulteradas, de acordo com as alegações da SEC. De 63 erros verificados, 29 envolviam manipulação dos recebíveis devido ao reconhecimento prematuro de receitas. Outros 14 casos envolviam alterações nos estoques. Quase sempre estes erros acabaram influenciando o lucro das empresas: em 50 das 58 empresas<sup>8</sup>, o efeito foi superior a 10% do lucro. Como muitos dos casos envolviam alterações nos lucros devido a “erros”, é razoável supor que a divulgação de um AAER pode ser considerada uma *proxy* para a ocorrência de fraudes.

De fato, pode-se encontrar diversos estudos que utilizam os AAERs como indicadores de fraude: Beneish (1997; 1999a; 1999b), Fanning e Cogger (1998), Lee et al (1999), Erickson et al (2004; 2006), Miller (2006) e Ettredge et al (2008). São raros os artigos que desenvolvem modelos de detecção de fraudes nos EUA e não utilizam os AAERs. Summers e Sweeney (1998), por exemplo, fizeram somente uma revisão das notícias do *Wall Street Journal*.

Beneish (1997; 1999a) também utiliza a mídia como fonte de informação a respeito da ocorrência de fraudes. Esta busca adicional é feita porque, de acordo com Feroz (1991), um terço dos AAERs têm origem em notícias divulgadas na imprensa financeira, e existe uma demora de 2 a 4 anos entre a violação e a divulgação do AAER. Portanto, caso se deseje utilizar apenas AAERs, é importante que o período de término do estudo seja aproximadamente 4 anos antes da

---

<sup>8</sup> O número de empresas não é igual ao número de erros verificados porque, em alguns casos, uma empresa pode manipular mais de uma conta.

data de publicação do último AAER analisado; não adotar este procedimento pode exacerbar os erros de classificação.

## 2.2 O triângulo da fraude e seus indicadores

Apesar de alguns autores afirmarem que não existe uma teoria formal que indique quais variáveis devem ser utilizadas na detecção de fraudes (LIN ET AL., 2003), existem conceitos e teorias que buscam explicar as causas das fraudes contábeis – e portanto podem servir como ponto de partida para a seleção e organização de variáveis.

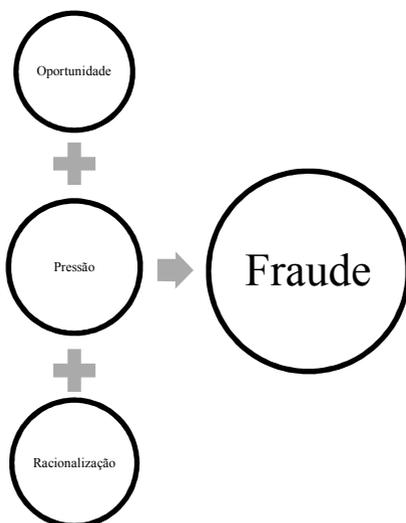
É comum o uso do conceito do *triângulo da fraude*, inicialmente proposto por Donald R. Cressey para explicar a ocorrência de crimes de colarinho branco em geral. Cressey acreditava que esses crimes ocorriam quando estavam presentes – ao menos para o infrator – três fatores: necessidade financeira, oportunidade e racionalização (Figura 1).

No início da década de 80, Steve Albrecht adaptou esta idéia para a contabilidade e para o estudo das fraudes nas demonstrações financeiras (CHOO; TAN, 2007).

O triângulo da fraude implica a possibilidade de interações entre estes diferentes fatores. Quando existem muitos incentivos para a fraude, até mesmo um gestor que normalmente é bastante ético pode ser compelido a reconsiderar suas definições de comportamento moralmente aceitável (TURNER ET AL., 2003).

Uma análise das variáveis normalmente utilizadas em modelos de detecção de fraudes revela que muitas delas se encaixam em um dos três elementos do triângulo da fraude, e por isso ele é frequentemente adotado como ponto de partida para a seleção e organização de variáveis em estudos similares (DESHMUKH; TALLURU, 1997). Portanto, o restante deste capítulo será dedicado a descrever cada um destes elementos e as variáveis que os compõem.

Vale ressaltar que o objetivo da seleção de variáveis não é identificar o maior número possível de variáveis. Na realidade, o uso de um grande número de variáveis pode causar problemas de multicolinearidade e dificultar a aplicação prática do modelo (GAGANIS, 2009). O ideal é obter um conjunto de indicadores capaz de revelar a situação da empresa em relação a cada um dos elementos do triângulo da fraude, de tal forma que os principais fatores subjacentes à decisão de fraudar (ou não) sejam representados no modelo.



**Figura 1: O “triângulo” da fraude: pressão, oportunidade e racionalização**

Fonte: adaptado de Turner et al. (2003)

### 2.2.1 Pressão e incentivos

A pressão está relacionada com a situação da empresa e dos executivos. Uma empresa que está sempre atingindo as expectativas do mercado não possui tanta necessidade de fraudar seus demonstrativos financeiros quanto uma empresa que passa por dificuldades. Por este motivo, indicadores de desempenho, liquidez e segurança financeira podem ser utilizados para a previsão de fraudes, em conjunto com outras evidências. A Enron, por exemplo, era uma empresa altamente alavancada, o que obrigava seus executivos a obter (e reportar) grandes lucros, para pagar os juros e cumprir as obrigações contratuais (CHOO; TAN, 2007).

Além disso, a remuneração variável dos executivos pode ter um papel importante na fraude. Também na Enron, Kenneth Lay (o CEO) obteve US\$ 217 milhões de lucro na venda de *stock options*, além de US\$ 19 milhões em salários e bônus. Estes benefícios possivelmente pesaram em sua decisão de manter a fraude.

### 2.2.1.1 Receitas, lucro e rentabilidade

Existem diversas variações de indicadores que mensuram as vendas, o lucro e a rentabilidade. O lucro, por exemplo, pode ser líquido ou antes dos impostos; a rentabilidade pode ser em relação ao ativo total ou às vendas. Através da combinação de diversas contas disponíveis nas demonstrações financeiras, pode-se criar um grande número de variáveis. Certamente não é viável descrevê-las todas aqui.

Na verdade, alguns dos indicadores de rentabilidade adotados neste trabalho não foram encontrados na literatura, pois se optou (como procedimento padrão) por normalizar as contas das demonstrações de resultado do exercício pela média do ativo total dos dois últimos anos. Os estudos similares costumam normalizá-las pelo ativo total do último ano. A justificativa para o procedimento aqui adotado é que o balanço reflete a situação da empresa apenas ao *final* do ano, enquanto a DRE mostra as vendas da empresa *ao longo* do ano. Para compatibilizar as duas demonstrações, tira-se a média do ativo total ao fim do período  $t$  e do ativo total ao fim de  $t-1$ ; essa média agora mostra o ativo médio da empresa *durante* o ano  $t$ .

A justificativa básica para o uso destas variáveis é que empresas que vêm apresentando resultados desfavoráveis – em termos de receitas, lucro e rentabilidade – estarão mais propensas à fraude.

Um destes indicadores pode ser construído utilizando-se as vendas da empresa:

$$VENAT_t = \frac{Vendas_t}{(AT_t + AT_{t-1})/2} \quad (2.1)$$

Gaganis (2009) adotou uma variável similar a essa última, porém sem usar a média do ativo total dos dois últimos anos; como esperado, concluiu que o indicador é menor em empresas acusadas (em empresas na Grécia).

Existem outros indicadores que utilizam as vendas. Alguns autores propõem dividir o custo dos produtos vendidos pelas vendas (KAMINSKI ET AL., 2004) ou usar a margem de lucro bruto (KAMINSKI ET AL., 2004; FANNING E COGGER, 1998; GAGANIS, 2009). Como essas duas variáveis estão altamente correlacionadas, será utilizada apenas a primeira:

$$CPVEN = \frac{\text{Custo dos produtos vendidos}}{\text{Vendas}} \quad (2.2)$$

Para Gaganis (2009), as empresas do grupo de tratamento possuem margem de lucro bruto significativamente maior. Fanning e Cogger (1998), estudando empresas norte-americanas, não verificaram diferença.

Outra opção é dividir os lucros antes dos impostos pelas vendas:

$$EBITVEN = \frac{EBIT}{\text{Vendas}} \quad (2.3)$$

Kirkos et al. (2007) e Spathis (2002), analisando empresas gregas, utilizaram o lucro *após* impostos e não obtiveram resultados significativos. Beneish (1999a) e Fanning e Cogger (1998) utilizaram o lucro antes dos itens extraordinários e obtiveram os mesmos resultados (para empresas norte-americanas). Apesar desses achados, essa variável será utilizada no estudo – pois é possível que a sua primeira diferença seja significativa. Também será testada a variável proposta por Spathis e Kirkos et al.:

$$LLVEN = \frac{\text{Lucro líquido}}{\text{Vendas}} \quad (2.4)$$

Também é possível utilizar o EBIT dividido pelo ativo total:

$$EBITAT_t = \frac{EBIT_t}{(AT_t + AT_{t-1})/2} \quad (2.5)$$

Essa variável é bastante similar ao ROA (retorno sobre ativos, ou *return on assets*) – a diferença é que o retorno é antes dos impostos e juros, e utiliza-se a média dos ativos. O ROA aqui utilizado será:

$$ROA_t = \frac{\text{Lucro líquido}_t}{(AT_t + AT_{t-1})/2} \quad (2.6)$$

Ainda não está clara a maneira como o ROA influencia a probabilidade de fraude, pois os resultados encontrados na literatura são bastante contraditórios. Crutchley et al. (2007), Erickson et al. (2006) e

Gaganis (2009) verificaram que o ROA é inferior entre as empresas acusadas; Summers e Sweeney (1998) e Wang (2004 e 2008) concluíram justamente o contrário. Skousen e Wright (2006) não obtiveram diferença significativa. Desta forma, o impacto dessa variável na fraude contábil ainda é uma questão em aberto.

Skousen e Wright (2006) propõem o uso do fluxo de caixa livre como *proxy* para a pressão:

$$\begin{aligned}
 FCL = & \text{Lucro líquido} + \text{Depreciação} \\
 & - \Delta \text{Capital de trabalho} \\
 & - \text{CAPEX}
 \end{aligned} \quad (2.7)$$

A justificativa é que empresas com fluxo de caixa livre negativo ou baixo terão maior necessidade de financiamento do que as demais empresas. De fato, estes autores verificaram empiricamente que as empresas acusadas tinham FCL significativamente menor do que o grupo de controle. Beneish (1999a), por sua vez, não obteve resultados estatisticamente significativos. Ettredge et al. (2008) preferem utilizar o fluxo de caixa operacional:

$$FCO = EBIT + \text{Depreciação} - \text{Impostos} \quad (2.8)$$

Esses autores verificaram que o grupo de tratamento possui uma *variação* do FCO superior às demais empresas.

### 2.2.1.2 Escore Z de Altman

O escore Z proposto por Altman (1968), originalmente utilizado para previsão de falências, também pode ser utilizado como *proxy* para as dificuldades financeiras enfrentadas pelas empresas. Quanto maior o valor de Z, melhor a situação da empresa – e, conseqüentemente, menor a probabilidade de que ela venha a fraudar seus balanços. Por este motivo, ela é utilizada em diversos modelos de detecção de fraude. Em Kirkos et al. (2007) e Spathis (2002), o Z é considerado negativamente relacionado com a fraude (como esperado). Nas análises univariadas de Fanning e Cogger (1998), Summers e Sweeney (1998) e Erickson et al. (2006), não há diferença entre os dois grupos de empresas. Os achados sugerem que o escore Z de Altman é útil na previsão de fraudes na Grécia, mas não nos EUA.

### 2.2.1.3 Indicadores de liquidez

Outro fator que pode pressionar uma empresa a recorrer à fraude é a falta de recursos para cumprir suas obrigações e manter-se competitiva. Por este motivo, foram propostos diversos indicadores relacionados à liquidez e à composição dos ativos de uma empresa (KAMINSKI ET AL., 2004). De maneira geral, espera-se que a fraude esteja negativamente relacionada com a liquidez.

O índice de liquidez corrente (abreviado como ILC), obtido através da divisão do ativo corrente pelo passivo corrente, é um deles:

$$ILC = \frac{\textit{Ativo corrente}}{\textit{Passivo corrente}} \quad (2.9)$$

Ele mostra se a empresa possui recursos suficientes para pagar suas contas de curto prazo (fornecedores e empréstimos, por exemplo). Os estudos encontrados apontam para a insignificância desta variável. (BENEISH, 1999b; KIRKOS ET AL., 2007)

Os diversos componentes do ativo de uma empresa possuem diferentes níveis de liquidez. Se uma rede de supermercados utilizar seu caixa para comprar produtos e aumentar seus estoques, o ILC não indicará a mudança ocorrida na liquidez da empresa – mas, sem dúvida, a empresa agora possui menor capacidade de pagar seu passivo de curto prazo e as despesas inesperadas. Por isso, propõe-se uma variável formada pela divisão do caixa pelo ativo total (CXAT):

$$CXAT = \frac{\textit{Caixa}}{\textit{Ativo total}} \quad (2.10)$$

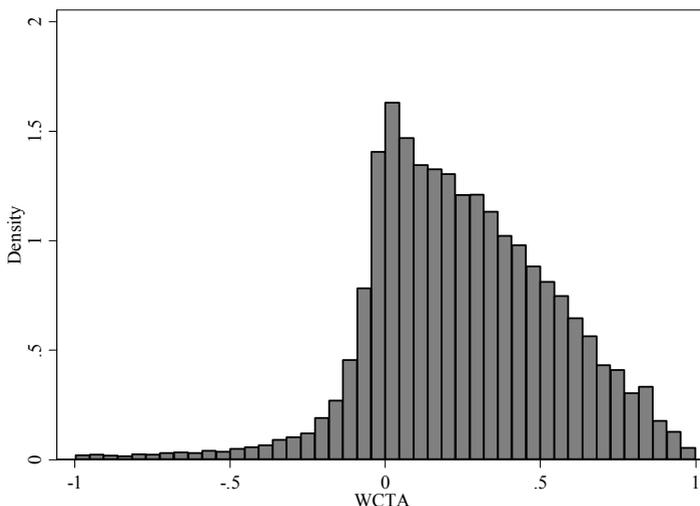
Espera-se que ela seja maior nas empresas do grupo de controle – como verificaram Gaganis et al. (2009).

Outra medida de liquidez frequentemente utilizada é o capital de trabalho (*working capital*) – obtido pela subtração do ativo corrente pelo passivo corrente – dividido pelo ativo total:

$$CTAT = \frac{(\textit{Ativo corrente} - \textit{Passivo corrente})}{\textit{Ativo total}} \quad (2.11)$$

Em uma análise univariada (teste *t* pareado), Kaminski et al. (2004) verificaram que essa variável é significativamente diferente entre os dois grupos (empresas que fraudaram e grupo de controle) nos anos seguintes

à fraude. Nos anos anteriores à fraude, ela não é relevante; mas deve-se observar que estes autores utilizaram um teste aparentemente inadequado, já que a variável CTAT não segue uma distribuição normal, mesmo que sejam retirados alguns *outliers* (Figura 2). Além disso, estes autores não reportam a média e a dispersão das variáveis utilizadas. Devido a esses problemas, os resultados de Kaminski et al. são sistematicamente desconsiderados ao longo desta análise.



**Figura 2: Histograma da variável CT/AT (capital de trabalho / ativo total)**

Gaganis (2009), Kirkos et al. (2007) e Spathis (2002) verificaram que empresas na Grécia que recorreram à fraude apresentam CTAT inferior às demais empresas. Estudando empresas norte-americanas, Beneish (1997, 1999a e 1999b) não encontrou nenhuma diferença entre o CT/AT dos dois grupos no ano anterior à fraude. Fanning e Cogger (1998) também não encontraram diferença entre o capital de trabalho dos grupos.

#### 2.2.1.4 Alavancagem

A alavancagem também pode ser um fator de pressão para os gestores de uma empresa. Ao contrário da liquidez, a alavancagem leva

em consideração todos os ativos e todos os passivos da companhia. Para quantificá-la, pode-se utilizar:

$$ALAV = \frac{Passivo\ Total}{Ativo\ Total} \quad (2.12)$$

Crutchley et al. (2007), Beneish (1997 e 1999a), Ettredge et al. (2008), Erickson et al. (2006), Wang (2004 e 2008) e Johnson et al. (2003) não conseguiram verificar uma diferença significativa entre a alavancagem das empresas acusadas e das outras. A exceção fica por conta de Beneish (1999b), que verificou uma alavancagem maior em empresas do grupo de tratamento, com significância estatística a 10%. A explicação para esta discrepância pode residir no período de estudo, que neste último caso situou-se entre os anos de 1987 e 1993. Os estudos mais recentes, naturalmente, incluíram outros casos na amostra. Crutchley et al., por exemplo, utilizou o período de 1990 a 2003.

Na China e na Grécia, essa variável foi significativamente maior em empresas que cometeram fraude (CHEN ET AL., 2006; KIRKOS ET AL., 2007; SPATHIS, 2002). Isto parece indicar que a alavancagem financeira possui relevância diferente em mercados emergentes.

Outra maneira de mensurar a alavancagem é utilizada por Fanning e Cogger (1998):

$$ALAVPATR = \frac{Passivo\ Total}{Patrimônio\ Líquido} \quad (2.13)$$

Esses mesmo autores, usando essa variável, verificaram que as empresas acusadas possuem – em média – alavancagem superior às demais.

### 2.2.1.5 Composição dos ativos

Existem algumas variáveis que buscam indicar a composição dos ativos das empresas. Um exemplo é a variável formada pela divisão das contas a receber pelo ativo total, utilizada em Kaminski et al. (2004):

$$CRAT = \frac{Contas\ a\ receber}{Ativo\ total} \quad (2.14)$$

Em Fanning e Cogger (1998), as empresas do grupo de tratamento possuem CRAT maiores, sendo que a diferença é

significativa a 5%. Esse indicador está relacionado à segurança financeira.

Outras variáveis utilizam o estoque. Tem-se, por exemplo:

$$ESTVEN = \frac{\text{Estoque}}{\text{Vendas}} \quad (2.15)$$

Um alto ESTVEN é sinal de que a empresa está com problemas; ela não está conseguindo vender seus produtos, que estão sendo acumulados nos estoques. De acordo com Gaganis (2009) e Fanning e Cogger (1998), ESTVEN é maior no grupo de tratamento. Para Kirkos et al. (2007) e Spathis (2002), não há diferença. Para Summers e Sweeney (1998), é relevante observar o *crescimento* do estoque em relação às vendas, que nas empresas acusadas foi maior no ano anterior à fraude.

$$ESTAT = \frac{\text{Estoque}}{\text{Ativo total}} \quad (2.16)$$

A justificativa das variáveis ESTAT é similar à de ESTVEN. Para Gaganis (2009), Kirkos et al. (2007) e Fanning e Cogger (1998), a variável é estatisticamente igual entre os grupos.

Outra variável é o ativo corrente dividido pelo ativo total:

$$ACAT = \frac{\text{Ativo corrente}}{\text{Ativo total}} \quad (2.17)$$

Em Gaganis (2009), essa variável é significativamente menor no grupo de tratamento. A proporção entre ativo fixo e ativo total também pode ser utilizada:

$$AFAT = \frac{\text{Ativo fixo}}{\text{Ativo total}} \quad (2.18)$$

De forma análoga ao ACAT, espera-se que empresas acusadas tenham AFAT maior. Apesar disso, para Kirkos et al. (2007), essa variável não é significativa. O AFAT não é comum na literatura, talvez por apresentar forte multicolineariedade com ACAT quando inserida em um modelo (no presente estudo, o coeficiente de correlação entre AFAT e ACAT é de -0,71).

Analisando esses indicadores em conjunto, pode-se esperar que as empresas acusadas tenham ativo corrente menor, menos dinheiro em caixa (e equivalentes), porém mais estoques e contas a receber. Isso é consistente com a hipótese de que problemas financeiros e falta de liquidez levem à fraude.

#### 2.2.1.6 Remuneração variável

As fraudes contábeis costumam ser cometidas pelos integrantes do alto escalão de uma empresa. Por isso os incentivos oferecidos a estas pessoas podem influenciar a probabilidade de fraude. É por esse motivo que a remuneração variável atrelada ao desempenho da empresa na bolsa de valores (*stock options*) é uma das variáveis frequentemente utilizadas em modelos de detecção de fraudes. Não há, porém, um consenso quanto à significância dessa variável. Existem tanto estudos que não encontram evidências quanto à relevância da remuneração variável (GERETY e LEHN, 1997; CRUTCHLEY ET AL., 2007) quanto estudos que afirmam o contrário (ERICKSON ET AL., 2004). Outra possibilidade é que o simples fato do executivo possuir ações da empresa, sem nenhuma restrição, já é capaz de aumentar a probabilidade de fraude (JOHNSON ET AL., 2003). Infelizmente, no Brasil, não é possível inserir tal variável no modelo com o uso de informações publicamente disponíveis. Tampouco foi possível obter esses dados para empresas norte-americanas.

#### 2.2.1.7 Outros indicadores de pressão

É comum o uso das contas a receber divididas pelas vendas (ou vice-versa) como indicador de segurança financeira. Assim:

$$RECCR = \frac{Vendas}{Contas a receber} \quad (2.19)$$

Quanto menor o RECCR, maior a proporção de vendas a prazo feitas pela empresa. Isto indica insegurança financeira, pois as receitas podem demorar algum tempo para estarem disponíveis para o pagamento de dívidas e novos investimentos. Por isso, espera-se que as empresas acusadas tenham RECCR menor.

Em Skousen e Wright (2006), o grupo de tratamento possui RECCR menor, como esperado. Em compensação, Summers e Sweeney

(1998) não encontraram diferença significativa. Já na Grécia, Gaganis (2009) e Kirkos et al. (2007) usaram contas a receber divididas pelas vendas e verificaram que essa variável era maior no grupo de tratamento – ou seja, as empresas acusadas possuíam RECCR menor, como esperado. Em contraste, Spathis (2002) não encontrou nenhuma diferença, usando o teste *t* pareado – que é inadequado quando os grupos possuem dispersões diferentes, como é o caso.

Também é possível obter uma *proxy* para segurança financeira através de (KAMINSKI ET AL., 2004):

$$DJPT = \frac{\text{Despesas com juros}}{\text{Passivo total}} \quad (2.20)$$

Uma empresa que possui um DJPT alto estará pagando juros bastante elevados pelos empréstimos que contraiu. Assim, um DJPT alto pode levar as empresas à fraude como uma maneira de obter financiamento mais barato. O único estudo encontrado que utiliza esta variável é o de Kaminski et al., que não encontrou nenhuma diferença significativa entre os dois grupos no ano anterior à fraude.

### 2.2.2 Oportunidade

O segundo elemento do triângulo da fraude é a oportunidade, que não deve ser entendida apenas como falta de regulamentação ou ausência de mecanismos de governança corporativa. Choo e Tan (2007) explicam que a intensa ênfase que a sociedade norte-americana deposita no sucesso monetário leva os executivos a desconsiderarem ou procurarem meios de burlar os mecanismos institucionais criados para coibir a fraude. Ou seja, mesmo que a oportunidade não esteja presente, em alguns casos os gestores irão ativamente procurar por maneiras de criá-las. Por isso, a própria pressão pelo sucesso acaba gerando oportunidades para o comportamento criminoso.

Neste espírito, os gestores de uma empresa acusada de fraude (Cendant) mantinham uma planilha anual com “oportunidades” disponíveis para inflacionar as receitas operacionais, além de listar os valores que deveriam ser obtidos em cada uma destas oportunidades (CHOO; TAN, 2007).

Existem algumas variáveis que funcionam como *proxy* para a oportunidade, baseadas em características dos auditores, nível de governança corporativa e controle pelos acionistas. Devido à

disponibilidade de dados, o presente estudo opta por focar as variáveis relacionadas aos auditores.

### 2.2.2.1 Auditoria

A oportunidade pode estar relacionada com o auditor da companhia. É possível utilizar uma variável *dummy* que seja igual a 1 quando as demonstrações da empresa forem auditadas por uma grande firma – ou seja, uma das que atualmente são conhecidas como *big four* (SHARMA, 2004). Ao utilizar esta variável, Sharma (2004) verificou que ela não era significativa em um modelo *logit*, na análise univariada, Gerety e Lehn (1997), além de Ettredge et al. (2008), não encontraram uma diferença significativa. Estudando empresas chinesas, Chen et al. (2006) também concluíram pela irrelevância desta variável. Estes resultados contrastam com os de Fanning e Cogger (1998), que verificaram que as empresas que fraudaram tinham uma menor proporção de auditores *big six*, com diferença estatisticamente significativa a 1%.

A mudança da firma de auditoria (MUDAUD) é uma das variáveis que podem indicar a oportunidade de fraude. É até mesmo possível que a empresa mude de auditor para diminuir a probabilidade de que a fraude seja detectada (Summers e Sweeney, 1998). Em uma análise univariada, Skousen e Wright (2006), Fanning e Cogger (1998) e Summers e Sweeney (1998) verificaram que não havia uma diferença significativa na proporção de mudanças de auditor entre as empresas dos dois grupos. Por outro lado, Ettredge et al. (2008) obtiveram uma relação positiva e significativa entre essa variável e a fraude.

### 2.2.3 Atitudes e racionalização

Em um ambiente social e corporativo em que o lucro é perseguido a qualquer custo, sem dúvida é mais fácil admitir a fraude como uma maneira aceitável de alcançar o sucesso. É neste que consiste a racionalização: a possibilidade que o executivo tem de justificar para si mesmo os seus atos. Bernie Ebbers – o CEO da WorldCom – certa vez afirmou que a criação de um código de conduta para os empregados seria uma perda de tempo colossal (CHOO; TAN, 2007). Se uma pessoa recusa-se a criar um código de ética para não “perder tempo” – o que ela não faria para garantir seu bônus no fim do ano?

### 2.2.3.1 Accruals

Descobrir as características do ambiente e da cultura de uma organização não é uma tarefa simples – ao menos com dados publicamente disponíveis. Para contornar este problema, Skousen e Wright (2006) propõem o uso dos *accruals* como *proxy*. Para esses autores, o nível de *accruals* é representativo da maneira como a administração toma decisões referentes às demonstrações financeiras. Quando o gerenciamento de resultados é visto como algo normal, talvez ações mais graves sejam o próximo passo.

Neste trabalho, considera-se os *accruals* totais (ACT) como (CUPERTINO e MARTINEZ, 2008; HRIBAR e COLLINS, 2002):

$$ACT = (\Delta AC - \Delta Cx) - (\Delta PC - \Delta Dív - \Delta Imp) - Dep \quad (2.21)$$

sendo que AC é o ativo circulante, Cx são as disponibilidades e investimentos de curto prazo, PC é o passivo circulante, Dív são os financiamentos (dívidas) de curto prazo, Imp são os impostos a pagar e Dep são as despesas de depreciação. Como de costume,  $\Delta$  é o operador de primeira diferença.

É normal que as empresas tenham despesas de depreciação e outros componentes não-financeiros em seus resultados, sem que isso signifique que ela esteja gerenciando seus resultados. Por isso, pode-se falar em *accruals* esperados (não-discrecionários), que são consequência natural da situação econômico-financeira da empresa. De acordo com o modelo de Jones (1991), os *accruals* esperados dependem do ativo permanente e da variação das receitas da empresa. Em um modelo com efeitos aleatórios, a equação é:

$$AT_{it} = \alpha + \beta_1 \Delta vendas_{it} + \beta_2 AP_{it} + v_i + \varepsilon_{it} \quad (2.22)$$

sendo que  $v_i$  é o componente que captura os choques que afetam apenas a empresa  $i$  ao longo de todo o período da amostra. Os *accruals* discrecionários são obtidos pela diferença entre os *accruals* totais e os *accruals* esperados. Existem outras metodologias, tais como os modelos modificado (Dechow et al, 1995) e adaptado (Dechow et al, 2003) de Jones, que também foram estimados, mas apresentaram resultados menos satisfatórios.

Apenas um autor concluiu que as empresas do grupo de tratamento têm *accruals* totais maiores que as empresas do grupo de controle (BENEISH, 1997 e 1999b). Em compensação, existem outros estudos que afirmam que os *accruals* são irrelevantes para a probabilidade de fraude (SKOUSEN e WRIGHT, 2006; KWASITSU, 2004).

Beneish (1999a) utiliza *accruals* discricionários, estimados de acordo com o modelo modificado de Jones. Em um modelo *probit*, esta variável teve coeficiente positivo e significativo a 5%, confirmando os resultados da análise univariada. Ettredge et al. (2008) utilizaram diversas medidas de *accruals* discricionários, e todas elas eram significativamente maiores no grupo de tratamento (com p-valor igual a zero até a segunda casa decimal). É importante ressaltar que esses autores não detalharam os modelos utilizados para estimar os *accruals* esperados (os artigos não mencionam os coeficientes obtidos, por exemplo); por isso, não é possível garantir que as técnicas econométricas eram adequadas.

Uma outra possibilidade – pouco documentada, mas que será explorada neste estudo, é o uso de *accruals* absolutos (*ACTABS*) – isto é, em módulo. Isto é interessante especialmente no mercado brasileiro, em que talvez nem todas as fraudes sejam realizadas com o objetivo de inflacionar o lucro.

Por fim, Skousen e Wright (2006) explicam que o uso excessivo de *accruals* é frequentemente citado no relatório de auditoria. Por este motivo, pode-se criar uma variável *dummy* (*NQUAL*) que assume o valor 1 caso o relatório apresente uma opinião não-qualificada (*unqualified*), e 0 caso seja *unqualified* mas tenha linguagem adicional.

### 2.3 Estudos similares

Os problemas de pesquisa relacionados às fraudes contábeis podem ser abordados de diversas maneiras. Entre os estudos quantitativos, uma das abordagens possíveis é baseada na metodologia de estudos de eventos – normalmente quando se deseja avaliar o impacto da fraude sobre os mercados e os investidores. Outra abordagem são os modelos econométricos, frequentemente utilizados quando o objetivo é detectar fraudes ou testar hipóteses sobre a influência de determinadas variáveis sobre a probabilidade de fraude. Por fim, têm-se os sistemas de inteligência artificial, que podem ser mais eficientes na detecção de fraudes, mas não permitem testes de hipóteses.

Nesta parte da dissertação, serão revistos os principais trabalhos sobre fraudes que se encaixam em uma dessas três categorias. São apresentados os métodos utilizados, os principais resultados e as contribuições relevantes.

### 2.3.1 Estudos de eventos

Existem estudos que verificam a reação do mercado à descoberta de fraudes contábeis, através da metodologia de estudo de eventos (*event study*). Para cada data, o autor estabelece o retorno esperado para uma empresa, normalmente fazendo uso do beta da ação e do retorno do mercado. A diferença entre o retorno observado e o retorno esperado é o *retorno anormal*. Se – no dia em que for anunciada uma republicação de demonstrações financeiras (dia do evento) – o retorno anormal das ações da empresa for negativo, então esta republicação ofereceu uma nova informação ao mercado – que reagiu a ela, derrubando os preços das ações. Este estudo costuma ser feito com diversas empresas, permitindo que sejam feitas generalizações acerca da importância das republicações como fonte de novas informações para o mercado. E, quando se estuda um período mais longo, tem-se o retorno anormal acumulado (*cumulative abnormal returns*, ou CAR).

Nessa linha, Palmrose et al. (2004) observaram que o CAR médio das ações, no dia do evento e no dia subsequente, é de  $-9,2\%$ , significativo ao nível de  $10\%$ . Quando a republicação (*restatement*) é decorrente de fraude contábil, o retorno anormal costuma ser ainda menor, pois coloca em dúvida a competência e a integridade da administração da empresa.

Os resultados podem ser diferentes quando o evento estudado é a divulgação da possível ocorrência da fraude, ao invés da republicação. Johnson et al. (2003) verificaram que o CAR médio das empresas acusadas, considerando-se o período entre dois dias antes e um dia após este evento, é de  $-19,78\%$ , com p-valor inferior a  $1\%$ . Feroz et al. (1991) chegaram ao valor de  $-10\%$  apenas no dia do evento, estatisticamente diferente de zero ao nível de  $1\%$ . Gerety e Lehn (1997) estudaram um período de 3 dias, e chegaram a um CAR médio de  $-3,05\%$ , também estatisticamente diferente de zero. A diferença nos resultados provavelmente decorre do período estudado: Gerety e Lehn utilizaram os anos entre 1981 e 1987, Feroz et al. analisaram o período entre 1982-1989, e Johnson et al. estudaram o período entre 1992 e 2001. Em

conjunto, os resultados parecem indicar um aumento do impacto da fraude sobre o mercado acionário ao longo dos anos.

Miller (2006) observou que, em certos casos de fraude (29% do total) a imprensa teve um papel de destaque, expondo a fraude antes da SEC. Verificou também que o mercado reage negativamente à publicação de reportagens investigativas (produzidas pelo próprio jornal ou revista) indicando a existência de fraudes. Isto sugere que as publicações da área de negócios são uma fonte legítima de informações sobre casos de fraude – ao menos para o mercado. Se a realidade brasileira for similar, então – em um estudo sobre fraudes – a coleta das informações publicadas em jornais poderia servir para complementar o uso das republicações ordenadas pela CVM como indicador da existência de fraude.

Alguns diretores são membros de conselhos de administração de mais de uma empresa. No caso de uma destas empresas ser acusada de fraude, é possível que a reação do mercado contamine as ações das outras empresas. Ou seja, a fraude criaria uma desconfiança não apenas em relação à empresa, como também ao diretor. O CAR médio das empresas em que pelo menos um dos diretores é membro do *board* de uma empresa acusada é de -0,98%, considerando-se o dia da fraude e o dia anterior (FICH; SHIVDASANI, 2007).

Gunthorpe (1997) percebeu que estes retornos anormais negativos não ocorrem apenas em casos de fraude, mas também quando há qualquer tipo de comportamento ilegal (infração de patentes, formação de cartel, corrupção etc). Este estudo também inclui diversos casos de fraude nas demonstrações financeiras. Em um período de sete dias, estas empresas tiveram retorno anormal acumulado médio de -2,32%. No dia do evento o retorno anormal foi de -1,32%, significativo a 1%. A autora conclui que – além das implicações morais – os resultados indicam que há um incentivo econômico para a incorporação da ética nos currículos das escolas de negócios.

Os artigos reportados acima mostram evidências consistentes de um impacto negativo da descoberta da fraude sobre o preço das ações. Isso mostra a relevância do presente estudo para a contabilidade e para o mercado de capitais. Ressalva-se que talvez estes dados estejam enviesados – pois é possível que diversos estudos que não rejeitaram a hipótese nula não chegaram a ser publicados, devido à conhecida preferência dos periódicos acadêmicos por artigos que cheguem a conclusões “interessantes”.

### 2.3.2 Modelos *probit* e *logit*

É bastante comum o uso de modelos *probit* e *logit*, normalmente utilizando os *Accounting and Auditing Enforcement Releases* (AAERs) da SEC para definir a variável dependente. O objetivo destes estudos pode ser testar hipóteses referentes às variáveis explanatórias ou desenvolver modelos de previsão (*forecasting*). Normalmente eles também adotam variáveis de controle, e quase sempre as empresas acusadas de fraude são comparadas com um grupo de controle; o estudo é do tipo *matched pair*. Nas próximas páginas é feita uma revisão dos artigos que adotam esses modelos, e os achados são resumidos na Tabela 1.

Beasley (1996) estudou o efeito da composição do conselho de direção (*board of directors*) na vulnerabilidade da empresa à fraude. A amostra era de 150 empresas, divididas em dois grupos (tratamento e controle). O período do estudo compreendia fraudes publicamente divulgadas (através de AAERs e do *Wall Street Journal Index*) no período entre 1980 e 1991. O WSJI teve importância secundária, pois 67 das 75 empresas acusadas foram descobertas através de AAERs.

Esse é um dos poucos estudos que não utilizam uma análise univariada para complementar e embasar a análise multivariada – que, no caso, é baseada em modelos *logit*. Verificou-se que, quanto maior a proporção de diretores externos, menor a probabilidade de fraude. Algumas características destes diretores externos também são importantes: tempo de serviço (coeficiente negativo), quantidade de ações possuídas por eles (coeficiente também negativo), e número de diretorias assumidas (positivo). Essas variáveis mostram que diretores mais comprometidos com a empresa (por possuírem ações ou estarem envolvidos com a empresa há mais tempo) são mais eficientes na prevenção de fraudes. Além disso, o número de membros do conselho possui coeficiente positivo, indicando que os grupos menores conseguem controlar melhor a qualidade das informações contábeis. Esse autor também verificou que a presença de um comitê de auditoria é irrelevante para a probabilidade de fraude.

**Tabela 1: artigos similares que utilizam modelos *probit* e *logit***

Autores	Ano	País	Modelo	Variável dependente
Beasley	1996	EUA	<i>logit</i>	AAER e WSJI
Beneish	1997	EUA	<i>probit</i>	AAER e jornais
Beneish	1999b	EUA	<i>probit</i>	AAER e jornais
Summers e Sweeney	1998	EUA	<i>logit</i>	WSJI
Lee et al.	1999	EUA	<i>logit</i>	AAER e WSJI
Abbott et al.	2000	EUA	<i>logit</i>	AAER
Spathis	2002	Grécia	<i>logit</i>	- <sup>9</sup>
Johnson et al.	2003	EUA	<i>logit</i>	AAER
Sharma	2004	Austrália	<i>logit</i>	-
Wang	2004	EUA	<i>probit</i> <sup>10</sup>	Processos judiciais
Brazel et al.	2005	EUA	<i>logit</i>	AAER
Skousen e Wright	2006	EUA	<i>logit</i>	AAER
Erickson et al.	2006	EUA	<i>logit</i>	AAER
Miller	2006	EUA	<i>logit</i>	AAER
Crutchley et al.	2007	EUA	<i>logit</i>	AAER
Fich e Shivdasani	2007	EUA	<i>logit</i>	Processos judiciais
Ettredge et al.	2008	EUA	<i>logit</i>	AAER
Wang	2008	EUA	<i>probit</i>	AAER e processos

Beneish (1997) também usou AAERs em conjunto com informações publicadas pela imprensa, no período entre 1987-1993, para identificar 64 firmas que violaram os GAAP (princípios contábeis geralmente aceitos). Foi estimado o modelo modificado de Jones (DECHOW ET AL., 1995), e o decil superior foi transformado no grupo de controle. Nesse trabalho, as empresas acusadas eram comparadas com *accruals* agressivo através de uma análise univariada baseada no teste *t* entre amostras independentes. O teste é claramente inadequado para algumas das variáveis estudadas por Beneish – o ativo total, por

<sup>9</sup> No caso de modelos desenvolvidos fora dos EUA, a tabela omite a variável dependente utilizada, pois as características da regulamentação destes outros mercados não são diretamente comparáveis com as do mercado norte-americano.

<sup>10</sup> Wang (2004 e 2008) modela separadamente a probabilidade de fraude e a probabilidade de detecção da fraude.

exemplo, certamente não segue uma distribuição normal. Para testar a diferença entre as medianas dos dois grupos, foi usado um teste identificado apenas como  $\chi^2$ , que se supõe ser o teste de Mood – um caso especial do teste  $\chi^2$  de Pearson. O teste tem baixo poder estatístico em amostras altamente desbalanceadas (GASTWIRTH; WANG, 1987), como é o caso (o grupo de tratamento tem 64 empresas; o de controle, 2.658). De qualquer maneira, o teste é considerado obsoleto (FREIDLIN; GASTWIRTH, 2000); o teste de média neste estudo, pelo menos, não é suscetível ao erro de tipo I (rejeitar incorretamente uma hipótese nula que é verdadeira). A análise multivariada usa dois modelos *probit* – um para *accruers* agressivos e outros para *accruers* agressivo com vendas crescentes. Estes modelos obtiveram pseudo- $R^2$  de 0,242 e 0,275, respectivamente. No teste de razão de verossimilhança, ambos os modelos rejeitam a  $H_0$ , com p-valor igual a zero até a terceira casa decimal. O autor chega à conclusão de que o modelo pode ser utilizado pela SEC, auditores e investidores para analisar um grande número de firmas em busca de potenciais manipuladores de resultados (que, naturalmente, deverão ser investigados mais a fundo antes de um conclusão definitiva).

Beneish (1999b) utilizou uma extensão do modelo *probit* (*weighed exogenous sample maximum likelihood probit* – WESML) na detecção de manipulação de resultados. A amostragem deste estudo não foi probabilística, de tal forma que o percentual de empresas fraudadoras na amostra era maior do que o percentual na população. O WESML corrige este problema ponderando a função de máxima verossimilhança de acordo com a proporção de empresas manipuladoras na amostra e na população.

Na análise univariada desse artigo, Beneish desta vez adotou o teste *rank-sum* de Wilcoxon – que é adequado para as variáveis utilizadas, caso os dois grupos tenham dispersões iguais. Foram utilizadas oito variáveis obtidas a partir de informações publicamente disponíveis, sendo que sete delas são construídas pela divisão de um dado contábil pelo valor deste mesmo dado no ano anterior. A probabilidade de fraude, portanto, é interpretada como sendo função de variações nos indicadores contábeis. Isto evita que características do setor industrial ou da própria empresa sejam confundidas com evidências de fraude. Além disso, o modelo ressalta mudanças súbitas nos indicadores – que normalmente são mais suspeitas do que mudanças gradativas.

O modelo WESML obteve pseudo- $R^2$  de 0,306; o modelo *probit* não-ponderado obteve 0,371. Ambos os modelos rejeitam a hipótese nula do teste de razão de verossimilhança ao nível de 1%. A vantagem do WESML é que as probabilidades de fraude previstas são mais próximas da realidade; quando a empresa realmente estava envolvida em uma FDF, a probabilidade média estimada foi de 9,7% (na amostra de validação). Com um modelo *probit* não-ponderado, essa probabilidade sobe para 18,1%.

É esperado que pessoas que detêm informações privilegiadas (*insiders*) irão vender suas ações antes que a existência de fraude se torne pública. Summers e Sweeney (1998) investigaram esta relação utilizando um modelo *logit* encadeado (*cascaded logit model*). A variável dependente foi obtida através da análise do *Wall Street Journal Index* no período de 1980 até 1987. A amostra final continha 57 casos de fraude. O modelo *logit* final (*second-tier*) apresentou pseudo- $R^2$  igual a 0,39 e rejeita a  $H_0$  no teste de razão de verossimilhança, com p-valor igual a 0,0002. Como o modelo não foi validado em uma amostra separada, não há sentido em reportar as taxas de acerto em previsões. Os autores concluíram que os *insiders* realmente diminuem seus investimentos em empresas envolvidas em fraudes (ou seja, vendem ações), de forma que estas informações contribuem para a detecção de fraudes.

Lee et al (1999) examinaram a relação entre lucros, fluxo de caixa e a probabilidade de fraude. As fraudes entre 1978 e 1991 foram identificadas através dos AAERs e do *Wall Street Journal Index*. A amostra final consistia em 56 firmas. Os autores realizaram uma análise univariada (aplicando o teste *t*) e utilizaram um modelo *logit*, chegando à conclusão de que a variável lucros menos fluxo de caixa operacional possui coeficiente positivo e é altamente significativa (p-valor igual a zero até a terceira casa decimal). O lucro também é significativo, mas possui p-valor maior. Chegou-se à conclusão de que a probabilidade de fraude nas demonstrações contábeis está principalmente relacionada à diferença entre lucros e fluxo de caixa operacional.

Abbott et al. (2000) estudaram o papel dos comitês de auditoria na prevenção das fraudes contábeis. Ao invés de mensurar apenas a presença ou não do comitê, esses autores adotam diversas variáveis relacionadas ao nível de independência e atividade do comitê. Para o grupo de tratamento, foram identificadas empresas sancionadas pela SEC por fraudes que ocorreram no período entre 1980 e 1996. Esses autores foram mais liberais na formação da amostra, pois incluíram também empresas que não foram diretamente acusadas de fraude, com a

lógica de que a contabilidade agressiva muitas vezes está apenas a um passo de práticas fraudulentas. Por isso, a amostra é relativamente grande: 254 casos, sendo que após a exclusão de empresas sem dados disponíveis ou para as quais não foi possível encontrar uma semelhante (para o grupo de controle), restaram 78 firmas. O modelo *logit* apresentado por esses autores rejeita a hipótese nula do teste de razão de verossimilhança ao nível de 1% e apresenta duas variáveis significativas: o crescimento e uma variável *dummy* que é 1 caso o comitê não possua nenhum empregado ou afiliado da empresa e se reúna pelo menos duas vezes no ano anterior à fraude. O coeficiente desta variável é negativo, como esperado. Em compensação, não foi encontrada relação entre a proporção de membros externos e a probabilidade de fraude – o que vai de encontro a estudos anteriores (Beasley, 1996).

Estudando empresas gregas, Spathis (2002) identificou 38 casos de fraude e escolheu outras 38 empresas para compor o grupo de controle. A análise univariada foi feita utilizando apenas o teste *t*. Os modelos *logit* mais adequados foram obtidos através do método *stepwise*. Um resultado interessante é que o uso do escore Z de Altman faz a probabilidade de identificação correta de empresa não-fraudulentas subir de 78,95% para 84,21%; o percentual de empresas fraudulentas corretamente identificadas, porém, cai de 86,84% para 84,21%. O uso desta variável, portanto, depende do custo de cada tipo de erro. É importante ressaltar que esses percentuais foram obtidos usando a amostra de teste, não há amostra de validação. Os modelos propostos por Spathis (com e sem Z) utilizam apenas três variáveis, e em ambos a relação entre as variáveis dependentes e independentes (teste de razão de verossimilhança) é estatisticamente significativa ao nível de 1%.

Limitando sua busca a fraudes ocorridas entre 1992 e 2001 (identificadas através da análise dos AAERs), Johnson et al. (2003) encontraram 43 casos de fraude que se estenderam por um total de 102 anos de demonstrações fraudulentas. O objetivo do estudo era verificar se os incentivos para executivos (*executive compensation*) afetavam a probabilidade de fraude. A análise univariada foi feita através de testes de igualdade de medianas; o artigo não traz detalhes, mas supõe-se que seja o teste de Mood. Também são usados modelos *logit*, mas os autores não reportam a estatística  $\chi^2$  nem a verossimilhança logarítmica – apenas o pseudo- $R^2$  de McFadden, que varia entre 0,66 e 0,39 (de acordo com a o tipo de incentivo usado como variável independente). O estudo conclui que apenas os incentivos oriundos de ações sem

restrições à venda (*unrestricted stock*) acarretam maior propensão à fraude.

Buscando estabelecer a relação entre o trabalho do comitê de diretores (*board of directors*) de uma empresa e a probabilidade de fraude, Sharma (2004) estudou 31 empresas que cometeram fraude na Austrália entre 1988 e 2000. A análise univariada identificou as variáveis que eram diferentes entre essas 31 empresas e o grupo de controle através do teste de Wilcoxon. As variáveis testadas eram referentes ao ano anterior à fraude, como no presente estudo. Todas as variáveis (mesmo as que não rejeitaram a  $H_0$  no teste de Wilcoxon) foram utilizadas em um modelo *logit*; obteve-se  $\chi^2$  igual a 26,7 e p-valor associado igual a 0,003. Esse modelo classificou corretamente 80,6% das empresas de ambos os grupos. A conclusão do trabalho é que a manutenção de comitês com grande proporção de membros independentes e nos quais o *chairman* não acumule a função de CEO pode diminuir o número de fraudes na Austrália.

Estudando a possibilidade de se prever fraudes através de indicadores não-financeiros (recursos humanos, patentes, número de subsidiárias etc.), Brazel et al. (2005) verificou os AAERs entre 1998 e 2003 e identificou 95 casos de fraudes, sendo que a amostra final foi reduzida para 93 devido a dados faltantes. Foram propostos diversos modelos *logit*, em todos era utilizada uma variável independente construída a partir de indicadores não-financeiros – que foi significativa em todos eles. Este estudo não tenta validar a capacidade preditiva destes modelos em uma amostra separada.

Verificando os AAERs emitidos entre 1992 e 2001, Skousen e Wright (2006) também construíram um modelo de previsão de fraudes contábeis. De um total de 113 empresas acusadas de FDF, sobraram 86 após a eliminação daquelas que não tinham dados disponíveis no Compustat. O triângulo da fraude foi utilizado como *framework* para a seleção de variáveis potencialmente relevantes. Destas, as variáveis que obtiveram p-valor inferior a 0,15 na análise univariada (usando teste *t* e de Wilcoxon) foram inseridas em um modelo *logit*. O teste da razão da verossimilhança rejeitou a hipótese nula de que este modelo era equivalente ao modelo restrito (apenas com constante) ao nível de 1%.

Assim como Johnson et al. (2003), o estudo de Erickson et al. (2006) utiliza um modelo *logit* para testar a hipótese de que incentivos financeiros aumentam a probabilidade de fraude. A amostra foi construída examinando-se AAERs emitidos entre 1996 e 2003. A amostra final era composta por 50 empresas acusadas e 100 empresas no grupo de controle. Também foi utilizada uma amostra não-pareada.

Chegou-se à conclusão de que não há indícios de que estes benefícios (*stock options*, por exemplo) tornem os executivos mais propensos à fraude. Estes autores também concluem que não há um aumento nas vendas de ações e no exercício de opções por parte de gestores de empresas envolvidas em fraudes. Este achado vai de encontro aos resultados obtidos por Summers e Sweeney (1998) e Johnson et al. (2003).

Através da análise univariada e de um modelo *logit*, Miller (2006) verificou que a visibilidade da empresa está positivamente correlacionada à probabilidade de fraude detectada. As *proxies* utilizadas para a visibilidade foram o interesse por parte da imprensa e dos analistas, e o valor de mercado. O artigo conclui que a imprensa privilegia a investigação de casos de fraude que atraem maior número de leitores e facilitem a obtenção de informações – ou seja, envolvendo empresas com maior visibilidade.

Utilizando AAERs, Crutchley et al. (2007) examinaram diversas características do ambiente corporativo de empresas acusadas de fraude. A amostra consistia em 97 empresas acusadas e um grupo de controle de mesmo tamanho. Todos os modelos *logit* apresentados foram significativos a 1%. Os autores chegaram à conclusão de que normalmente as fraudes ocorrem em um ambiente caracterizado por rápido crescimento, acentuado gerenciamento de resultados, poucos *outsiders* no comitê de auditoria e diretores externos sobrecarregados (isto é, que trabalham em vários outros comitês).

Fich e Shivdasani (2007) examinaram o impacto da fraude sobre a reputação dos diretores externos da empresa acusada. Diferentemente de muitos outros trabalhos, esses autores identificam as fraudes com base em processos judiciais abertos pelos acionistas (ao invés da SEC). No período entre 1998 e 2002, foi encontrado um total de 685 processos envolvendo 580 empresas. Como é preciso que estas empresas tenham dados disponíveis em alguma base (Compustat, por exemplo), várias observações foram perdidas, resultando em uma amostra final de 216 firmas. É interessante observar que o período desses autores é o mesmo desta dissertação, mas a amostra é maior devido à metodologia. Entre outras análises, o artigo traz um modelo *logit* para estimar a probabilidade de abertura de ação judicial contra uma empresa. De forma inovadora, utiliza-se como variável independente a existência de um diretor que está envolvido (também como diretor) com outra empresa acusada de fraude. Verificou-se que a presença de tal diretor de fato aumenta a probabilidade de fraude em uma empresa. O p-valor do

teste de razão de verossimilhança (do modelo) é inferior a 0,1%. Conclui-se que existe um fenômeno de contágio da fraude através dos comitês de diretores.

Ettredge et al (2008) utilizam um modelo *logit* para testar a hipótese de que a probabilidade de fraude está positivamente correlacionada com os impostos diferidos. Verificou-se que o coeficiente desta variável é positivo e estatisticamente significativo, com *p-value* de 6%, quando o modelo é utilizado para detectar fraudes no mesmo ano em que elas ocorrem. Quando o modelo é utilizado para prever a probabilidade de ocorrência de fraude no ano seguinte, o *p-value* dos impostos diferidos passa a ser de 8%. Nesse caso, todos os modelos rejeitam a  $H_0$  do teste de razão de verossimilhança ao nível de 1%, exceto o modelo que utiliza firmas que registraram prejuízo antes dos impostos.

Os artigos mais próximos do que esta dissertação se propõe a fazer são os de Wang (2004 e 2008). Essa autora explica que não é possível observar diretamente a probabilidade de fraude nem a probabilidade de detecção; o que se observa é a probabilidade de *fraude detectada* – que é obtida pela multiplicação das duas probabilidades anteriores. Estudar a variável composta pode levar a inferências incorretas, pois determinados indicadores podem ter influências opostas sobre as duas variáveis latentes (fraude e detecção). Por exemplo, empresas grandes podem ter menor probabilidade de fraudar e, ao mesmo tempo, maior probabilidade de serem pegas caso fraudem. Utilizando uma abordagem econométrica inicialmente proposta por Poirier (1980), Wang modela separadamente os dois processos latentes, conseguindo controlar a não-observabilidade das fraudes cometidas mas não detectadas.

As duas variáveis latentes podem ser representadas, em notação matricial, como:

$$\begin{aligned} F_i^* &= \mathbf{x}_{F,i} \boldsymbol{\beta}_F + u_i \\ D_i^* &= \mathbf{x}_{D,i} \boldsymbol{\beta}_D + v_i \end{aligned} \quad (2.23)$$

Sendo que  $\mathbf{x}_{F,i}$  e  $\mathbf{x}_{D,i}$  são os vetores das variáveis que explicam a ocorrência e a detecção de fraude, respectivamente. As variáveis binárias são:

$$\begin{aligned} F_i &= 1 \text{ se } F_i^* > 0; \text{ caso contrário } F_i = 0 \\ D_i &= 1 \text{ se } D_i^* > 0; \text{ caso contrário } D_i = 0 \end{aligned} \quad (2.24)$$

As informações disponíveis (AAERs, por exemplo) apenas mostram quando ambas as variáveis são iguais a 1. Portanto:

$$Z_i = F_i D_i \quad (2.25)$$

Por isso, a probabilidade de um AAER ser emitido ou não devem ser estimadas como:

$$\begin{aligned} \Pr(Z_i = 1) &= \Pr(F_i = 1, D_i = 1) \\ \Pr(Z_i = 0) &= \Pr(F_i = 0, D_i = 0) \\ &\quad + \Pr(F_i = 1, D_i = 0) \end{aligned} \quad (2.26)$$

Essas definições são apresentadas com o intuito de mostrar que a abordagem de Wang (2008) tem a vantagem de permitir a estimação da probabilidade de detecção de fraude, *condicional* a um vetor  $\mathbf{x}_{D,i}$ . Isso permite *insights* a respeito dos fatores que a SEC e outros órgãos regulamentadores levam em consideração ao tentar identificar casos de fraude. Além disso, abre-se a possibilidade de estudos que analisem as relações dinâmicas entre os vetores  $\mathbf{x}_{F,i}$  e  $\mathbf{x}_{D,i}$ . Poderia-se verificar, por exemplo, se as variáveis do vetor  $\mathbf{x}_{D,i}$  mudam com o tempo, de forma a refletir mais adequadamente as verdadeiras causas da fraude; afinal, o jogo que se estabelece entre as empresas que fraudam suas demonstrações e as agências de controle do mercado não é estático; é esperado que as armas de cada um dos lados mudem e sofisticuem-se com o tempo.

Um dos problemas da proposta de Wang é a dificuldade de validação do modelo. Ao mesmo tempo que se espera que as probabilidades estimadas sejam mais precisas que as de outros modelos mais simples, não é possível testá-las em uma amostra de validação – justamente pela observabilidade parcial da variável  $F_i$ . Essa é uma limitação compartilhada com o presente estudo, que também não pode ser testado desta maneira. Isto não impede, porém, que o modelo seja utilizado para investigar as causas da fraude.

Outro problema do artigo de Wang (2008) é que ele não estabelece qual a probabilidade incondicional de detecção de fraude. Para finalidades de políticas públicas – isto é, acompanhar a eficácia do trabalho da SEC – essa probabilidade é importante. Esse valor também pode permitir que futuros trabalhos estimem o impacto das fraudes na economia. O presente estudo busca suprir esta lacuna.

### 2.3.3 Inteligência artificial

Existem também estudos que adotam técnicas de inteligência artificial para estimar a probabilidade de fraude contábil (o resumo da revisão dos artigos referentes à aplicação destes métodos à detecção de fraude pode ser visto na Tabela 2). Fanning et al. (1995) desenvolveram dois tipos de redes neurais artificiais, além de um modelo *logit*. As RNAs foram treinadas em uma amostra de 150 companhias, sendo que 37 delas eram fraudulentas. Na amostra de validação (*holdout sample*), a melhor RNA (chamada de *adaptive logit network*, ou ALN) foi capaz de identificar corretamente 75% das empresas com fraude nas demonstrações e 92% das empresas sem fraude. O modelo *logit*, em comparação, obteve percentuais de acerto de 70% e 91%, respectivamente.

**Tabela 2: artigos similares que utilizam inteligência artificial**

Autores	Ano	País	Técnica	Variável dependente
Fanning et al.	1995	EUA	RNA	-
Deshmuck e Talluru	1997	EUA	<i>fuzzy</i>	-
Fanning e Cogger	1998	EUA	RNA	AAER
Lin et al.	2003	EUA	FNN	AAER
Gottlieb et al.	2006	EUA	SVM	AAER
Kirkos et al.	2007	Grécia	várias	-
Ogut et al.	2009	Grécia	SVM e RNA	-
Gaganis	2009	Grécia	várias	-

Também é possível aplicar a teoria dos conjuntos nebulosos (*fuzzy set theory*) à detecção de fraudes (DESHMUKH; TALLURU, 1997). Esses autores desenvolveram variáveis linguísticas baseadas no triângulo da fraude – condições (C), motivação (M) e racionalização (A); se uma dessas variáveis não estivesse presente, o modelo considerava a probabilidade de fraude como sendo igual a zero. Foi criada então uma tabela de regras que determinava, a partir das variáveis C, M e A, o risco de fraude. Por exemplo, se a empresa possuía C médio, M alto e A baixo, a probabilidade de fraude era média. Os autores concluem que o modelo é uma maneira intuitiva e eficiente de aplicar os *red flags* em situações reais de auditoria.

Fanning e Cogger (1998) desenvolveram uma rede neural capaz de identificar corretamente 66% das empresas acusadas e 59% das demais. O modelo *logit* obteve percentuais de 67% e 33%, respectivamente. Neste estudo, as empresas fraudulentas foram identificadas através dos AAERs emitidos no período entre 1980 e 1993. Os autores concluem que, além de mostrar a eficácia das redes neurais, o estudo contribui identificando variáveis relevantes para a detecção de fraudes.

Aplicando um rede neural *fuzzy* (FNN) a uma amostra de empresas acusadas de fraude pela SEC no período entre 1980 e 1995, Lin et al. (2003) preveram corretamente 7 casos de fraude de um total de 20 (35%); o modelo *logit*, por sua vez, identificou apenas um deles. É interessante observar que o modelo *logit* é mais eficiente na identificação de empresas não-fraudulentas, com taxa de acerto de 97,5% (contra 86,3% da FNN). A decisão entre usar um modelo ou outro, portanto, depende da relação entre o custo do erro de tipo I e o custo do erro de tipo II.

Gottlieb et al. (2006) inovaram ao utilizar dados trimestrais (1996-2005). Os balanços eram considerados fraudulentos quando a empresa era processada com sucesso pela SEC, ou era feito um acordo, devido à uma fraude que incluía o trimestre em questão. Uma mesma empresa pode fraudar vários balanços, dando origem a diversas observações consideradas fraudulentas. Esta metodologia, portanto, é significativamente diferente dos outros trabalhos analisados. Os resultados indicam que a *support vector machine* (SVM) obteve os melhores resultados (área abaixo da curva ROC igual a 0,72); surpreendentemente, o modelo *logit* obteve resultados apenas um pouco piores (área igual a 0,65). Os autores concluem que os resultados são animadores, encorajando novas pesquisas.

Kirkos et al. (2007) fizeram um estudo comparativo entre três técnicas de mineração de dados (*decision trees*, redes neurais e *bayesian belief network* - BBN). Os modelos foram aplicados a 76 empresas da Grécia, divididas igualmente entre firmas acusadas e grupo de controle. Os melhores resultados foram obtidos pela BBN, que classificou corretamente 90,3% das empresas da amostra de validação. A rede neural, em comparação, acertou apenas 80% das vezes. Uma ressalva a este estudo é que foram utilizadas apenas variáveis financeiras. O uso de variáveis como mudança de auditor ou composição do *board*, por exemplo, poderia melhorar significativamente os modelos utilizados.

Esses resultados são melhores que os obtidos por Ogut et al. (2009), também para empresas gregas. Esses autores, usando *support vector machines* e redes neurais probabilísticas, obtiveram 70% e 60% de acertos, respectivamente. Ressalva-se que esses modelos não são diretamente comparáveis com os de Kirkos et al., pois a amostra é diferente: esse autor usou 75 empresas acusadas e formou um grupo de controle com outras 75 empresas. Aktas et al. (2007), utilizando os mesmos dados, obtiveram 53,33% de acertos para os modelos *logit* e *probit*. Em conjunto, esses dados mostram que as técnicas de inteligência artificial têm o potencial de apresentar resultados consideravelmente superiores aos modelos *logit* e *probit*.

Gaganis (2009) realizou um abrangente estudo comparando diversas técnicas de previsão e detecção de fraudes. Os dados utilizados eram referentes a empresas gregas, compreendendo o período 2001-2004 e 199 empresas que emitiram demonstrações fraudulentas. Entre as diversas técnicas, as que obtiveram melhor resultados foram UTADIS (*Utilités Additives Discriminantes*) e PNN (*Probabilistic Neural Network*), ambas com precisão de 90,24%. A que obteve pior resultado foi a análise *logit*, com acerto de 84,15%. Quando se utilizam apenas dados financeiros como variáveis independentes, porém, o acerto da análise *logit* passa a ser comparativamente melhor (82,30%), superando as redes neurais artificiais (80,49%) e ficando atrás apenas de apenas três das 10 técnicas utilizadas (UTADIS, MHDIS e PNN).

Apesar de obterem bons resultados, os métodos de inteligência artificial não permitem estabelecer a relevância de cada uma das variáveis independentes, o que é importante para a compreensão dos fatores que estimulam e inibem a ocorrência de fraudes contábeis. Não seria possível, por exemplo, verificar se a probabilidade de fraude está ou não relacionada com a remuneração variável. Por este motivo, é importante corrigir a especificação utilizada em modelos *probit* e *logit*, de forma a evitar os vieses causados pelos erros de classificação.

#### 2.3.4 Estudos correlatos no Brasil

Não foi encontrado nenhum trabalho que tenha como objetivo criar um modelo para identificação ou previsão de fraudes contábeis no Brasil. Existem, porém, estudos que abordam fraudes contábeis e temas correlatos – republicações e gerenciamento de resultados, por exemplo.

Já existem tentativas no sentido de quantificar as fraudes contábeis no Brasil. Murcia et al. (2005) identificaram as causas que levaram a CVM a ordenar a republicação de demonstrações financeiras

no período entre 2001 e 2004. Os problemas identificados pela CVM foram classificados em dois grandes grupos: aqueles que afetam o lucro da empresa e aqueles que consistem na apresentação de informações insuficientes. É muito comum, por exemplo, que a CVM alegue “informações faltantes”. O primeiro grupo são casos que podem ser classificados como fraude contábil; o segundo grupo é muito mais duvidoso: a falta de informações pode ser tanto um erro inocente quanto uma tentativa de ocultar alguma fraude.

Esses mesmo autores fazem a ressalva de que a CVM removeu alguns destes documentos, argumentando que a página estava “sobrecarregada de informação”; usando informações divulgadas em jornais e revistas, os autores conseguiram recuperar algumas republicações que não estavam na página. Isso mostra a dificuldade que o pesquisador enfrenta no Brasil, sendo obrigado a lidar com um ambiente institucional pouco transparente. Por isso, uma alternativa seria o estudo de periódicos não-acadêmicos como fonte de informações sobre fraudes, já que frequentemente eles noticiam casos de fraude (MURCIA e BORBA, 2005).

Murcia e Borba (2007) explicam que existem sinais de alerta (*red flags*) que indicam a existência de um ambiente fraudulento. Conhecê-los pode ajudar o auditor e outras pessoas a prevenir e detectar a fraude. Eles indicam que a empresa está em risco e deve ser investigada mais a fundo; são, desta forma, conceitualmente muito similares às variáveis utilizadas no presente estudo. A diferença é que alguns *red flags* são informações de difícil acesso ao público em geral; e quase todos não são sistematizados em um banco de dados como o Compustat. Um exemplo de *red flag* é o caráter desonesto ou duvidoso de alguns executivos da empresa, além de uma administração não-ética. Esse também é um exemplo de informação que não está disponível de forma sistematizada. Isso dificulta o uso em modelos que envolvam centenas ou milhares de empresas.

Analisando diversos *red flags* encontrados na literatura, Murcia e Borba identificaram 6 grandes *clusters* de indicadores de fraudes: (a) estrutura e ambiente; (b) setor (indústria); (c) gestores da entidade; (d) situação econômico-financeira; (e) relatórios contábeis; e (f) auditoria. A existência de tantas variáveis envolvidas na fraude sugere que os modelos existentes poderiam ser significativamente melhorados, caso fosse possível utilizar variáveis referentes a todos estes *clusters*.

De maneira geral, trabalhos sobre fraudes são praticamente inexistentes no Brasil. Murcia e Borba (2005) realizaram um estudo

bibliométrico sobre fraudes, analisando oito periódicos acadêmicos nacionais, e encontraram apenas três trabalhos que abordavam o gerenciamento de lucros e a contabilidade criativa. O gerenciamento de resultados é uma área de pesquisa correlata à fraude; na verdade, a linha que separa o gerenciamento da fraude às vezes é tênue.

A importância deste trabalho para o estudo das fraudes baseia-se no fato de os motivos que levam os executivos a gerenciar resultados podem ser os mesmos que os levam a fraudar. Verifica-se, de fato, a ocorrência de *earnings management* no mercado brasileiro com diversos objetivos: (a) não reportar prejuízos trimestrais e anuais; (b) diminuir a variabilidade do lucro e manter a credibilidade perante investidores; (c) piorar os resultados presentes (quando eles são muito ruins) com a finalidade de obter lucro no futuro (MARTINEZ, 2001). Esses achados podem embasar futuros trabalhos sobre fraudes no mercado brasileiro.

Uma diferença fundamental entre o gerenciamento de resultados e a fraude é que, enquanto aquele não é capaz de enganar o mercado por muito tempo, esta raramente é descoberta (como os resultados do presente estudo indicam). Um investidor pode optar por investir somente em empresas com baixos níveis de *accruals*, mas não poderá estar completamente seguro de que a contabilidade dessas empresas estão de acordo com as normas contábeis.

Por fim, existem trabalhos que exploram as possibilidades oferecidas pelo estudo das republicações ordenadas pela CVM. Baptista (2008) estudou as diferenças entre as empresas que tiveram que republicar suas demonstrações financeiras e as que não tiveram. Apesar disso, o foco do estudo não era a fraude contábil, mas sim o gerenciamento de resultados. Verificou-se que as empresas que republicaram apresentam maior endividamento, menor liquidez, menor rentabilidade patrimonial, menor rentabilidade para o acionista, menor exposição ao risco, menor expectativa de crescimento, maior concentração acionária, menor volatilidade dos retornos das ações e menores *accruals* discricionários.

Os trabalhos sobre republicações são importantes para o estudo das fraudes, já que podem servir como base para a construção de uma *proxy* para a ocorrência de fraude. Isso, porém, ainda depende de uma metodologia diferenciada e consideravelmente mais complexa, como será visto no capítulo referente ao método.

## 2.4 Modelos de escolha binária

Modelos de previsão e detecção de fraudes contábeis normalmente utilizam variáveis dependentes binárias que indicam a ocorrência de fraude ( $Y=1$ )<sup>11</sup> ou não ( $Y=0$ ) para cada observação. No lado direito da equação, tem-se um conjunto de variáveis que influenciam a probabilidade de fraude. É possível – uma vez estimados os coeficientes de cada uma das variáveis independentes – calcular a probabilidade de que um determinado conjunto de demonstrações financeiras tenha sido manipulado. Estes modelos também permitem estimar o efeito marginal de cada uma das variáveis independentes sobre a probabilidade de  $Y=1$ , auxiliando no entendimento das causas das fraudes contábeis.

É possível estimar um modelo linear de escolha binária, expresso em notação matricial como

$$y = \mathbf{x}'\boldsymbol{\beta} + \varepsilon \quad (2.27)$$

Atualmente, essa abordagem raramente é utilizada. Essa especificação possui o inconveniente de não ser possível restringir  $\mathbf{x}'\boldsymbol{\beta}$  ao intervalo  $]0,1[$ . Não é possível garantir, portanto, que as previsões desse modelo pareçam ser probabilidades (GREENE, 2003). Para contornar esse problema, é usual utilizar no lado direito uma função de distribuição cumulativa – cujos contradomínios possuem o intervalo desejado. Existem várias funções que podem ser utilizadas. De maneira geral, tem-se uma função  $F$ , e o modelo passa a ser:

$$\text{Prob}(Y = 1|\mathbf{x}) = F(\mathbf{x}'\boldsymbol{\beta}) \quad (2.28)$$

É comum usar a distribuição normal cumulativa no lugar de  $F$ . Neste caso:

$$\text{Prob}(Y = 1|\mathbf{x}) = \int_{-\infty}^{\mathbf{x}'\boldsymbol{\beta}} \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}t^2} dt = \Phi(\mathbf{x}'\boldsymbol{\beta}) \quad (2.29)$$

---

<sup>11</sup> Aqui, adota-se a convenção de que  $Y$  representa o valor real (observado) da variável  $y$ .

Neste caso, o modelo é conhecido como *probit*. Caso seja adotada a distribuição logística, tem-se o modelo *logit*:

$$\text{Prob}(Y = 1|\mathbf{x}) = \frac{e^{\mathbf{x}'\boldsymbol{\beta}}}{1 + e^{\mathbf{x}'\boldsymbol{\beta}}} = \Lambda(\mathbf{x}'\boldsymbol{\beta}) \quad (2.30)$$

É possível utilizar outras distribuições – por exemplo, a Weibull – mas não foram encontrados exemplos de seu uso em modelos de detecção de fraudes. Vale ressaltar que o uso de uma função ou outra não acarreta mudanças significativas às probabilidades estimadas. Amemiya (1981) observa que é possível comparar os coeficientes estimados de um modelo *probit* ( $\widehat{\boldsymbol{\beta}}_{\phi}$ ) com aqueles de um modelo *logit* ( $\widehat{\boldsymbol{\beta}}_{\Lambda}$ ), através da relação

$$1,6\widehat{\boldsymbol{\beta}}_{\phi} \approx \widehat{\boldsymbol{\beta}}_{\Lambda} \quad (2.31)$$

O problema de escolher a distribuição de probabilidades teoricamente mais adequada ao problema de detecção de fraudes contábeis é, portanto, de menor relevância.

A estimação destes modelos é feita utilizando-se o método de máxima verossimilhança (MV). Dado o modelo da eq. 2.28, pode-se expressar a probabilidade conjunta de acerto (também conhecida como função de verossimilhança) como sendo

$$\begin{aligned} \text{Prob}(Y_1 = y_1, Y_2 = y_2, \dots, Y_n = y_n | \mathbf{X}) \\ = \prod_{y_i=0} [1 - F(\mathbf{x}'_i \boldsymbol{\beta})] \prod_{y_i=1} F(\mathbf{x}'_i \boldsymbol{\beta}) \end{aligned} \quad (2.32)$$

Quanto mais próximo de  $y_i$  estiver o valor de  $F(\mathbf{x}'_i \boldsymbol{\beta})$  – isto é, quanto mais confiáveis forem as estimativas obtidas – maior será o valor dos produtórios. Um modelo perfeito resultaria em  $\text{Prob}(Y_1 = y_1, Y_2 = y_2, \dots, Y_n = y_n | \mathbf{X}) = 1$ . Como  $y_i$  e  $\mathbf{x}'_i$  são valores conhecidos, pode-se perceber que as melhores estimativas de  $y_i$  serão obtidas encontrando-se o vetor  $\boldsymbol{\beta}$  que maximiza a função 2.32. É possível reescrever esta função como

$$L(\boldsymbol{\beta}) = \prod_{i=1}^n [F(\mathbf{x}'_i \boldsymbol{\beta})]^{y_i} [1 - F(\mathbf{x}'_i \boldsymbol{\beta})]^{1-y_i} \quad (2.33)$$

A partir desta forma, é simples aplicar o logaritmo e obter a função de verossimilhança logarítmica

$$\ln L(\boldsymbol{\beta}) = \sum_{i=1}^n \{y_i \ln F(\mathbf{x}'_i \boldsymbol{\beta}) + (1 - y_i) \ln [1 - F(\mathbf{x}'_i \boldsymbol{\beta})]\} \quad (2.34)$$

Sabendo que a função 2.34 é globalmente côncava, pode-se maximizar  $\ln L(\boldsymbol{\beta})$  encontrando a raiz da primeira derivada desta função em relação a  $\boldsymbol{\beta}$  ( $\partial \ln L / \partial \boldsymbol{\beta}$ ). Aplicando a derivada parcial, obtemos as equações de verossimilhança

$$\frac{\partial \ln L}{\partial \boldsymbol{\beta}} = \sum_{i=1}^n \left\{ \frac{y_i f(\mathbf{x}'_i \boldsymbol{\beta})}{F(\mathbf{x}'_i \boldsymbol{\beta})} + (1 - y_i) - \frac{f(\mathbf{x}'_i \boldsymbol{\beta})}{[1 - F(\mathbf{x}'_i \boldsymbol{\beta})]} \right\} \mathbf{x}_i = 0 \quad (2.35)$$

Sendo que a função  $f$  é a derivada da função  $F$ . A eq. 2.35 é aplicável a qualquer função de probabilidades que seja escolhida, mas o processo utilizado para resolver as equações de verossimilhança depende desta função. Os casos mais comuns – *probit* e *logit* – serão analisados separadamente.

#### 2.4.1 Modelo *logit*

No caso do modelo *logit*, pode-se simplificar 2.35 para<sup>12</sup>

$$\frac{\partial \ln L}{\partial \boldsymbol{\beta}} = \sum_{i=1}^n (y_i - \Lambda_i) \mathbf{x}_i = 0 \quad (2.36)$$

Uma das vantagens do modelo *logit* é que a tarefa de encontrar as derivadas de segunda ordem da função de verossimilhança logarítmica é bastante simples (embora só seja encontrada após alguma manipulação matemática):

---

<sup>12</sup> Sendo que  $\Lambda_i = \Lambda(\mathbf{x}'_i \boldsymbol{\beta})$

$$\mathbf{H} = \frac{\partial^2 \ln L}{\partial \boldsymbol{\beta} \partial \boldsymbol{\beta}'} = - \sum_i \Lambda(\mathbf{x}'_i \boldsymbol{\beta}) [1 - \Lambda(\mathbf{x}'_i \boldsymbol{\beta})] \mathbf{x}_i \mathbf{x}'_i \quad (2.37)$$

A matriz das derivadas parciais de segunda ordem da função de verossimilhança logarítmica – conhecida como matriz hessiana ( $\mathbf{H}$ ) – descreve a curvatura local desta função em um determinado ponto. Uma característica importante desta matriz é que ela é sempre negativa, ou seja, a função de verossimilhança logarítmica é globalmente côncava. Além disso, quando as derivadas de segunda ordem de  $\ln L$  forem contínuas, a matriz  $\mathbf{H}$  será simétrica em torno da diagonal principal<sup>13</sup>.

O método de Newton-Raphson exige que seja conhecida a derivada de segunda ordem da função que se deseja otimizar. Por esse motivo, a matriz hessiana é importante: ela permite – através desse método iterativo – que se resolva a equação 2.36. A solução obtida é justamente o ponto de máximo da função de verossimilhança logarítmica (4.8) para o modelo *logit*. A consequência prática disso é que o  $\boldsymbol{\beta}$  assim encontrado é aquele que melhor se ajusta ao modelo especificado.

#### 2.4.2 Modelo *probit*

Para o modelo *probit*, a função  $f$  será a função de densidade normal ( $\phi$ ). Assim, para este caso específico, tem-se

$$\ln L = \sum_{y_i=0} \ln[1 - \Phi(\mathbf{x}'_i \boldsymbol{\beta})] + \sum_{y_i=1} \ln \Phi(\mathbf{x}'_i \boldsymbol{\beta}) \quad (2.38)$$

Para encontrar o ponto de máximo da função de verossimilhança logarítmica, resolve-se a equação

---

<sup>13</sup> Isso é importante porque, se a matriz se torna assimétrica para determinado vetor  $\boldsymbol{\beta}$ , não é possível continuar o processo de maximização da verossimilhança logarítmica. É condição, para o uso do método de MV, que a derivada de segunda ordem da função  $\ln L$  seja contínua. No caso de um modelo *probit* simples, essa condição é sempre satisfeita. Mas, quando a função de MV é alterada, manter a simetria da matriz hessiana pode tornar-se problemático.

$$\frac{\partial \ln L}{\partial \boldsymbol{\beta}} = \sum_{y_i=0} \frac{-\phi(\mathbf{x}'\boldsymbol{\beta})}{1 - \Phi(\mathbf{x}'\boldsymbol{\beta})} \mathbf{x}_i + \sum_{y_i=1} \frac{\phi(\mathbf{x}'\boldsymbol{\beta})}{\Phi(\mathbf{x}'\boldsymbol{\beta})} \mathbf{x}_i = 0 \quad (2.39)$$

Mas, para resolver a equação acima pelo método de Newton, é preciso conhecer a derivada de segunda ordem da função 2.38. Para o modelo *logit* isso é relativamente simples. No caso do modelo *probit*, deve-se simplificar a equação 2.39 antes que seja possível prosseguir. Isso é feito utilizando-se a seguinte propriedade das funções simétricas:

$$1 - F(\mathbf{x}'\boldsymbol{\beta}) = F(-\mathbf{x}'\boldsymbol{\beta}) \quad (2.40)$$

Através dessa propriedade, é possível simplificar os dois somatórios da função 2.39. Basta fazer  $q = 2y - 1$ , de tal forma que

$$\frac{\partial \ln L}{\partial \boldsymbol{\beta}} = \sum_{i=1}^n \left[ \frac{q_i \phi(q_i \mathbf{x}'_i \boldsymbol{\beta})}{\Phi(q_i \mathbf{x}'_i \boldsymbol{\beta})} \right] \mathbf{x}_i = \sum_{i=1}^n \lambda_i \mathbf{x}_i = 0 \quad (2.41)$$

Existe outra propriedade útil da função de distribuição normal: para qualquer  $z$ ,

$$\frac{d\phi(z)}{dz} = -z\phi(z) \quad (2.42)$$

Com isso podemos encontrar a matriz das derivadas de segunda ordem (a matriz hessiana) da função de verossimilhança logarítmica

$$\mathbf{H} = \frac{\partial^2 \ln L}{\partial \boldsymbol{\beta} \partial \boldsymbol{\beta}'} = \sum_{i=1}^n -\lambda_i (\lambda_i + \mathbf{x}'_i \boldsymbol{\beta}) \mathbf{x}_i \mathbf{x}'_i \quad (2.43)$$

### 2.4.3 Estimação da matriz de covariância

A matriz de covariância pode ser estimada obtendo-se a inversa da matriz hessiana para o vetor  $\boldsymbol{\beta}$  encontrado. Alternativamente, pode ser utilizado o estimador de Berndt, Hall, Hall e Hausman

$$\mathbf{B} = \sum_{i=1}^n g_i^2 \mathbf{x}_i \mathbf{x}_i' \quad (2.44)$$

Caso seja adotado um modelo *probit*, mas ele não esteja corretamente especificado (por exemplo, há heterocedasticidade ou variáveis omitidas), então a inversa da matriz hessiana ( $\mathbf{H}^{-1}$ ) e o estimador  $\mathbf{B}$  não são consistentes.

Nesse caso, para evitar estatísticas *t* enviesadas, os erros padrões podem ser estimados pelo método *jackknife*, deletando-se um dos grupos a cada iteração. Para MacKinnon e White (1985), esse é o método que produz melhores resultados em amostras finitas, ao menos quando comparado com os estimadores propostos por White (1980), Hinkley (1977) e uma abordagem baseada em Horn, Horn e Duncan (1975). Outra vantagem do método *jackknife* é que ele produz resultados satisfatórios mesmo na ausência de heterocedasticidade – o que é importante, pois os testes de heterocedasticidade disponíveis não são completamente confiáveis.

Quando não for viável (computacionalmente) utilizar o método *jackknife*, pode-se adotar o estimador rubusto de White. Ele é definido como:

$$\text{Var}[\hat{\beta}] = [\hat{\mathbf{H}}]^{-1} \hat{\mathbf{B}} [\hat{\mathbf{H}}]^{-1} \quad (2.45)$$

É razoável supor que qualquer modelo de detecção de fraudes construído a partir de dados contábeis publicamente disponíveis sofra do problema de variáveis omitidas. Por este motivo, deve-se privilegiar o uso do estimador robusto de White e do método *jackknife* na estimação da matriz de variância e covariância.

## 2.5 Erros de classificação

De acordo com Schneeweiss e Augustin (2006), um modelo com erro de medição (*measurement error model*) é um modelo de regressão (linear ou não-linear) com substanciais erros de medição nas variáveis – especialmente na variável dependente. Esses erros são encontrados em quase todos os campos de aplicação da econometria.

Em modelos lineares, erros de medição na variável dependente não enviesam os coeficientes estimados, apesar de acarretarem estatísticas menos precisas (HAUSMAN, 2001). Mas, quando a variável

dependente é limitada de alguma maneira (como em um modelo *probit* ou *logit*), o vetor  $\beta$  não é mais consistente; os testes de significância, conseqüentemente, são inválidos. Nesse caso, diz-se que há *erro de classificação* (*misclassification*).

É importante observar que, quando os erros de classificação são independentes da matrix  $\mathbf{X}$ , os coeficientes são atenuados. Quando a probabilidade de erro está correlacionada com as variáveis independentes, porém, é possível que o viés seja em favor da rejeição da hipótese nula (NEUHAUS, 1999). Isso é bem provável em modelos de identificação de fraudes; as variáveis independentes muito provavelmente também são relevantes para explicar a detecção da fraude, e o modelo tende a rejeitar a  $H_0$  dos testes dos coeficientes mais frequentemente do que deveria. Isso indica que é possível que algumas variáveis significativas encontradas em estudos similares na realidade não o sejam.

Em modelos *probit* e *logit*, a variável dependente  $\tilde{y}_i$  usualmente é expressa como função de uma variável latente observável  $I_i$  e um limiar desconhecido  $I_i^*$ , de tal forma que (GUJARATI, 2006):

$$\begin{aligned}\tilde{y}_i &= 1 \text{ sempre que } I_i > I_i^* \\ \tilde{y}_i &= 0 \text{ sempre que } I_i < I_i^*\end{aligned}\quad (2.46)$$

Quando ocorrem erros de classificação na variável dependente, as condições acima não são respeitadas. A variável observada  $y_i$  nem sempre será igual à variável real  $\tilde{y}_i$ . O modelo passa a ter dois novos parâmetros,  $\alpha_0$  e  $\alpha_1$ , tal que:

$$\begin{aligned}\alpha_0 &= \text{Prob}(y_{it} = 1 | \tilde{y}_{it} = 0) \\ \alpha_1 &= \text{Prob}(y_{it} = 0 | \tilde{y}_{it} = 1)\end{aligned}\quad (2.47)$$

No caso das fraudes contábeis, o erro mais relevante é o da segunda equação – ou seja, a probabilidade de que uma empresa fraudadora não seja classificada como tal (tipo II). Espera-se que o outro tipo de erro (tipo I) seja muito raro, com valor próximo de zero e estatisticamente insignificante. Na verdade, para garantir a convergência dos modelos, adota-se a premissa de que  $\alpha_0 = 0$ .

Com a presença de erros de classificação, o valor esperado de  $y_i$  é (HAUSMAN et al, 1998):

$$\begin{aligned} E(y_i|\mathbf{x}_i) &= \text{Prob}(y_i = 1|\mathbf{x}_i) \\ &= \alpha_0 + (1 - \alpha_0 - \alpha_1)F(\mathbf{x}'_i\boldsymbol{\beta}) \end{aligned} \quad (2.48)$$

Sendo que  $\mathbf{x}_i$  é o vetor de variáveis explanatórias da observação  $i$  e  $F$  é a distribuição cumulativa de probabilidades adotada. No caso específico em que  $\alpha_0 = \alpha_1 = 0$ , a expressão acima passa a ser  $F(\mathbf{x}'_i\boldsymbol{\beta})$ , como nos modelos de escolha binária encontrados nos livros-texto de econometria. Restringindo  $\alpha_0 = 0$ , tem-se:

$$\begin{aligned} E(y_i|\mathbf{x}_i) &= \text{Prob}(y_i = 1|\mathbf{x}_i) \\ &= (1 - \alpha_1)F(\mathbf{x}'_i\boldsymbol{\beta}) \end{aligned} \quad (2.49)$$

Neste caso específico, substituindo-se  $F$  pela função cumulativa normal, a função de verossimilhança é:

$$L(\alpha_1, \boldsymbol{\beta}) = \prod_{i=1}^n \frac{[1 - (1 - \alpha_1)\Phi(\mathbf{x}'_i\boldsymbol{\beta})]^{1-y_i}}{[(1 - \alpha_1)\Phi(\mathbf{x}'_i\boldsymbol{\beta})]^{y_i}} \quad (2.50)$$

E a função de verossimilhança logarítmica é:

$$\begin{aligned} \ln L &= \sum_{y_i=0} \ln[1 - (1 - \alpha_1)\Phi(\mathbf{x}'\boldsymbol{\beta})] \\ &\quad + \sum_{y_i=1} \ln[(1 - \alpha_1)\Phi(\mathbf{x}'\boldsymbol{\beta})] \end{aligned} \quad (2.51)$$

Na prática, o procedimento do modelo com erros de classificação deste estudo é encontrar os valores de  $\alpha_1$  e  $\boldsymbol{\beta}$  que maximizam a função 2.51. Isso é feito através do método de Newton-Raphson.

No problema de detecção de fraudes contábeis, a existência de um viés causado pelos casos não descobertos é um problema apontado por vários dos estudos já publicados (LEE et al.; 1999, SUMMERS e SWEENEY, 1998; BENEISH, 1999). Erickson et al. (2006) concordam e, além disso, deixam explícito que seus testes se apóiam na premissa de que firmas acusadas pela SEC têm maiores probabilidades de estarem

envolvidas em fraudes do que aquelas que não foram acusadas<sup>14</sup> (esse pressuposto, porém, não é suficiente para se obter estimadores de máxima verossimilhança consistentes). Apesar dessa preocupação com a possibilidade de ocorrência de erros de classificação, nenhum dos artigos encontrados implementou alguma estratégia capaz de corrigi-los, ou mesmo procurou investigar a magnitude do viés causado por esse problema.

---

<sup>14</sup> Nas palavras dos autores: “*what our tests rely on is the probability that a firm engaged in fraud is greater for firms accused of fraud by the SEC than it is for firms not accused by the SEC*”.



### 3 METODOLOGIA

Esta seção descreve os procedimentos de coleta de dados e os testes estatísticos utilizados. A seção 3.1 explica como foram obtidos os dados referentes às fraudes nos EUA. A seção 3.2 discorre acerca das republicações ordenadas pela CVM e dos entraves que dificultam o uso dessas republicações como variável dependente em estudos sobre fraudes no Brasil. Na seção 3.3, é explicado o procedimento de formação de um grupo de controle para o estudo *matched pair*. Por fim, a seção 3.4 mostra os testes estatísticos adotados neste estudo.

#### 3.1 Amostra (EUA)

Em consonância com diversos outros estudos vistos na revisão dos trabalhos similares, as empresas acusadas de FDF são identificadas por meio dos *Accounting and Auditing Enforcement Releases* divulgados pela SEC, obtidos na página da internet da própria SEC ([www.sec.gov](http://www.sec.gov)).

Foram analisados os AAERs emitidos desde 01/01/1998 (#1004) até 04/12/2008 (#3072). Não foi feito nenhum tipo de busca; todos os relatórios foram lidos em busca de indícios de fraude material.

Caso a empresa realmente tivesse sido acusada de fraude (e não de corrupção, por exemplo), o relatório era lido cuidadosamente para identificar o primeiro ano em que houve alguma demonstração fraudulenta. Nesse ponto, havia o cuidado de verificar qual era o ano fiscal da empresa acusada. O Compustat adota uma regra simples: se o ano fiscal termina entre 1º de janeiro e 31 de maio, ele é considerado como sendo o ano de calendário anterior. Por exemplo, um balanço patrimonial fechado no dia 31 de março de 2000 é armazenado como sendo referente ao ano de 1999. Portanto, se uma fraude foi identificada neste balanço, considera-se o ano inicial da fraude como sendo 1999. Em outras palavras, foi feito um esforço para que a lista de fraudes e seus respectivos anos fosse compatibilizada com os dados do Compustat.

Foram eliminados da amostra os casos de violação do *Foreign Corrupt Practices Act* (FCPA), que reprime a prática de corrupção ativa envolvendo oficiais de países estrangeiros. Como corrupção é ilegal, o dinheiro utilizado para tais fins não pode ser oficialmente contabilizado; normalmente são feitas algumas manobras contábeis para esconder o destino dos recursos. Isso termina por afetar materialmente as demonstrações contábeis. Infelizmente, nem todos os AAERs referentes

a violações do FCPA trazem explicitamente quais demonstrações foram afetadas; em outros casos, o valor desviado é irrisório. Por esse motivo, optou-se por desconsiderá-los todos.

Também foram eliminados os casos de *backdating* de opções. O principal motivo foi a dificuldade de encontrar variáveis explanatórias relacionadas a esse tipo de fraude, que é muito mais gerencial do que contábil. Estaria-se, na verdade, misturando na mesma variável dependente dois fenômenos diferentes: fraude contábil com a finalidade de manipular os resultados de uma empresa que possivelmente não está conseguindo atingir as expectativas do mercado, e fraude gerencial com o objetivo de desfaltar os acionistas através daquilo que é efetivamente um desvio de recursos. Vale lembrar que o *backdating* de opções também pode acabar por distorcer as demonstrações.

Devido a limitações técnicas, foram utilizadas apenas as empresas que eram negociadas em uma destas três bolsas de valores: NYSE, NASDAQ ou AMEX. Isso significa que as empresas negociadas no mercado de balcão (*over the counter*) foram excluídas. As empresas que não possuíam dados no Compustat também foram excluídas.

Como a análise univariada não exige que a empresa possua todos os dados para ser realizada, não foram excluídas empresas que tinham dados faltantes. Por esse motivo, na análise univariada, os grupos podem ter tamanhos diferentes.

Foram removidos da amostra os casos de fraude ocorridos antes de 1998 e após 2002, já que muitos dos casos mais recentes de fraude ainda não foram descobertos. Para justificar essa decisão, a Figura 3 mostra a evolução dos casos de fraude descobertos entre 1998 e 2008. É fácil perceber que o número de fraudes cai abruptamente após 2002, o que traria um viés significativo para o estudo.

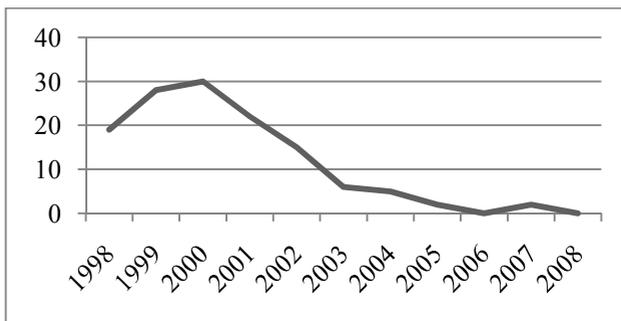


Figura 3: evolução do número de AAERs entre 1998 e 2008

Também foram removidas da amostra as empresas financeiras, isto é, as empresas que tinham códigos SIC entre 6000 e 6999. A amostra final consiste em 114 empresas que preenchem os requisitos necessários. Essa é a amostra que será considerada na análise multivariada com a amostra completa. Para a análise univariada, é preciso parear as empresas acusadas com outras similares, para formar o grupo de controle. Como não foi possível parear todas as empresas, foram perdidas 10 observações, restando 104 observações úteis. Um resumo do processo de seleção dessa amostra pode ser visto na Tabela 3.

**Tabela 3: empresas acusadas de fraude**

Empresas negociadas em bolsa (NYSE, NASDAQ ou AMEX)	
acusadas de fraude em AAERs emitidos entre 1998 e 2009	238
(-) Ano inicial da fraude antes de 1998 ou após 2002	105
(-) Empresas do setor financeiro	19
(=) Amostra da análise multivariada	114
(-) Empresas sem <i>matched pair</i>	10
(=) Amostra da análise univariada	104

O estudo não é feito apenas com empresas acusadas de fraude. As outras empresas são utilizadas na análise multivariada e podem ser selecionadas para compor o grupo de controle na análise univariada. A população do estudo era composta por todas as empresas negociadas na NYSE, na NASDAQ ou na AMEX – exceto ADRs – disponíveis no Compustat<sup>15</sup>.

Uma análise sucinta do número de observações disponíveis em toda a população de estudo pode ser vista na Tabela 4. É possível perceber que o número de empresas varia – o que é natural, pois novas companhias são listadas e outras fecham ou resolvem sair da bolsa. Como não é utilizado um painel balanceado, não há necessidade de excluir da amostra as empresas que não tenham dados disponíveis em todos os anos. Tal procedimento seria extremamente prejudicial para o trabalho, pois muitas empresas acusadas de fraude acabam saindo da bolsa. Na realidade, a análise multivariada utiliza dados *empilhados* (*pooled*); não há nenhum tipo de controle para a heterogeneidade entre as unidades *cross-section* ou entre os anos.

<sup>15</sup> O acesso ao Compustat foi gentilmente cedido pela biblioteca Karl A. Broedecker, da Fundação Getúlio Vargas (SP).

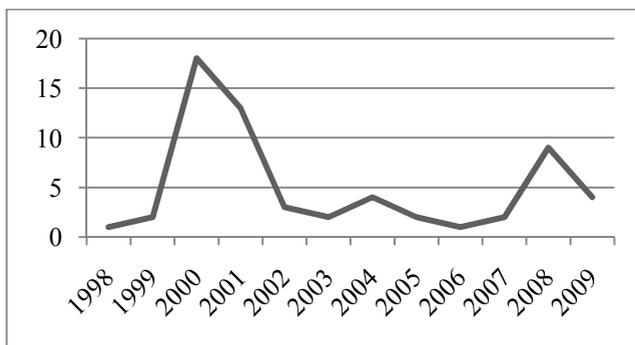
**Tabela 4: população de estudo**

Empresas listadas em 1998	7538
(-) Empresas financeiras em 1998	1497
(+) Empresas listadas em 1999	7322
(-) Empresas financeiras em 1999	1547
(+) Empresas listadas em 2000	6848
(-) Empresas financeiras em 2000	1481
(+) Empresas listadas em 2001	6520
(-) Empresas financeiras em 2001	1448
(+) Empresas listadas em 2002	6483
(-) Empresas financeiras em 2002	1449
(=) Observações da amostra final	27289

### 3.2 Amostra (Brasil)

A página na internet da CVM traz as republicações solicitadas a partir de 2001. O número de republicações mostradas nessa página, porém, é menor que o número mostrado por Baptista (2008) para o mesmo período. Isso indica que há uma inconsistência entre a fonte primária e a secundária. A Figura 4 mostra a evolução do número de republicações no Brasil; para período entre 1998 e 2006 foram utilizados dados de Baptista (2008); para 2007, 2008 e 2009, o número de republicações foi encontrado na página da CVM.

A viabilidade do uso das republicações ordenadas pela CVM como *proxy* para fraude contábil depende da adequação destes dados à premissa do método proposto por Hausman (1998):  $\alpha_0 + \alpha_1 < 1$ .



**Figura 4: evolução do número de republicações ordenadas pela CVM entre 1998 e 2009**

Se nem todas as republicações ordenadas estiverem disponíveis na página da CVM, como sugere a discrepância encontrada entre o número de republicações encontradas no site e no trabalho de Baptista (2008), então é possível que o uso da página da CVM como fonte para a definição da variável dependente aumente desnecessariamente o valor de  $\alpha_1$ . Se algumas das republicações encontradas em Baptista (2008) mas ausentes na página da CVM eram decorrentes de casos de fraude, então o número de casos descobertos será menor do que poderia ser. Isso contribui para dificultar a adequação das republicações à premissa necessária para a aplicação do modelo.

Os valores de  $\alpha_0$  e  $\alpha_1$  são desconhecidos, mas – no caso da SEC – é viável pressupor  $\alpha_0 = 0$ . Os AAERs utilizados referem-se especificamente a fraudes, principalmente casos que a SEC acredita que vale a pena processar a empresa acusada; portanto é muito pouco provável que um número significativo de empresas acusadas sejam, na realidade, inocentes.

No Brasil, este pressuposto dificilmente é mantido, pois a CVM não explicita a ocorrência de fraude. Isso pode ser demonstrado pela análise de algumas determinações. Considerando-se, por exemplo, a determinação de republicação emitida em 19/01/2009, referente ao terceiro formulário ITR da Votorantim Celulose e Papel S/A: não houve uma verdadeira manipulação das receitas ou do balanço patrimonial da empresa. Na verdade, a CVM apenas solicitou que a empresa esclarecesse adequadamente a sua política de utilização de instrumentos derivativos financeiros. Não há nenhuma menção a uma eventual contabilização incorreta do valor destes instrumentos. Claramente, não houve fraude contábil. Caso esta republicação fosse utilizada em um

modelo de identificação de fraudes, ela seria um caso de erro de classificação do tipo falso-positivo. Apenas isso já invalidaria o pressuposto de que  $\alpha_0 = 0$ .

Existem outras situações que não são claras: foi solicitado à Mendes Júnior Engenharia S/A que republicasse suas demonstrações financeiras referentes ao exercício financeiro encerrado em 2006, sob a justificativa de que a alteração da metodologia de cálculo para atualização monetária de dívidas vencidas não resultou em melhor apresentação ou informação mais confiável. Como saber se esta alteração foi feita para acobertar uma eventual fraude ou foi apenas uma decisão infeliz?

Enquanto bastaria eliminar a Votorantim da amostra como forma de manter a condição  $\alpha_0 = 0$ , não há como garantir que o caso da Mendes Júnior não seja um falso-positivo. E, sabendo-se que o coeficiente  $\alpha_1$  é bastante elevado em modelos voltados para o mercado norte-americano (como será visto nos resultados), é de se supor que basta alguns casos de falso-positivo para que a convergência do modelo para dados brasileiros não seja alcançada.

O fato de  $\alpha_0 + \alpha_1$  ser superior a 1 no Brasil também invalidaria os modelos *probit* e *logit* sem erros de classificação, pois a estimativa de  $\beta$  ficaria com o sinal trocado, e consequentemente os testes de hipóteses seriam inválidos.

Em decorrência dessas dificuldades, o presente estudo abstém-se de aplicar a metodologia proposta às empresas brasileiras. Mas, sem dúvida, este é um desafio que pode (e deve) ser vencido por pesquisas futuras. Para tanto, o importante é encontrar uma *proxy* que permita ao pesquisador pressupor  $\alpha_0 = 0$  e identificar um número substancial de fraudes contábeis.

### 3.3 Formação do grupo de controle

Se a análise univariada for realizada com todas as empresas para as quais se possui dados disponíveis, não será possível garantir que o teste está realmente levando em consideração *apenas* a relação da variável escolhida com a ocorrência de fraude. Se uma variável  $x$  está relacionada com a fraude e  $y$  está relacionada com  $x$ , então um teste estatístico poderá dar a falsa impressão de que  $y$  também está relacionada com a fraude. Para evitar a interferência destas variáveis estranhas, adotou-se a metodologia *matched pair*: para cada empresa acusada de fraude, escolhe-se outra (que não tenha sido acusada) que

seja o mais parecida possível com a primeira. Assim, pode-se ter maior segurança de que as ocasionais diferenças entre elas estejam realmente relacionadas com a fraude.

Para cada uma das 114 empresas acusadas, foi escolhida uma empresa para compor o grupo de controle. Para ser elegível, a empresa (a) deveria possuir os mesmos 4 primeiros dígitos do código SIC; (b) não poderia ter sido (naquele ano) acusada de fraude; e (c) a diferença entre os ativos totais da firma de controle e firma acusada não poderia ser superior a 30% do ativo total desta última. Se mais de uma empresa atendia a estas condições, então a empresa com o ativo total mais próximo era selecionada.

Em dez casos, não foi possível encontrar uma empresa que atendesse a todas as condições exigidas. Essas empresas foram descartadas do estudo. Por isso, o estudo *matched pair* contou com um total de 208 observações, sendo 104 empresas que foram alvo de investigação da SEC, e 104 empresas selecionadas para formar o grupo de controle.

### 3.4 Testes estatísticos

Sabendo-se que boa parte das variáveis utilizadas neste estudo não seguem uma distribuição normal, é preciso utilizar um teste estatístico não-paramétrico.

Um teste que se enquadra nas necessidades deste estudo, além de ser muito utilizado em estudos similares, é o teste U de Mann-Whitney-Wilcoxon (MANN e WHITNEY, 1947). É considerado um teste de mediana, apesar de frequentemente citado como teste de diferença entre medianas (BERENSON e LEVINE, 1996), e é capaz de identificar também diferenças nas distribuições (formato da curva e dispersão) dos dois grupos (HART, 2001). Por isso, é mais correto afirmar que a hipótese nula deste teste é que duas amostras independentes (grupos) se originam da mesma distribuição (ANDERSON AT AL., 1996).

Para se calcular a estatística U, deve-se ranquear todas as observações, da maior à menor. Soma-se o *rank* de todas as observações que se originam da menor amostra; este valor é chamado  $T_1$ . A soma dos *ranks* das observações do outro grupo é  $T_2$ . Os tamanhos destas amostras são  $n_1$  e  $n_2$ , respectivamente. Se a amostra for grande, pode-se utilizar uma aproximação normal:

$$z = \frac{T_1 - \mu_{T_1}}{\sigma_{T_1}} \quad (3.1)$$

Sendo que  $\mu_{T_1}$  é o valor esperado da estatística sob a  $H_0$ :

$$\mu_{T_1} = \frac{n_1(n+1)}{2} \quad (3.2)$$

E  $\sigma_{T_1}$  é o desvio-padrão de  $T_1$ :

$$\sigma_{T_1} = \sqrt{\frac{n_1 n_2 (n+1)}{12}} \quad (3.3)$$

Conhecendo-se o valor de  $z$ , basta utilizar os valores tabelados da distribuição normal para verificar se  $z$  é superior ao valor crítico ao nível de significância desejado.

No estudo de Monte Carlo, deseja-se testar se os estimadores são estatisticamente diferentes (isto é, se um deles é enviesado). Nesse caso, não é possível usar o teste de Mann-Whitney-Wilcoxon, pois os dados são pareados. Adota-se, portanto, a aproximação normal do teste do sinal (ANDERSON et al., 1996). Para  $n$  observações e duas variáveis ( $y$  e  $z$ ), conta-se o número de vezes em que uma delas é maior do que a outra; esta contagem é chamada de  $x$ . Se as duas medianas são iguais, então a probabilidade de  $y$  ser maior do que  $z$  é igual à probabilidade de  $z$  ser maior do que  $y$ ; sob a hipótese nula, espera-se que esta probabilidade seja igual a:

$$\mu = 0.50n \quad (3.4)$$

E que o desvio-padrão de  $\mu$  seja igual a:

$$\sigma = \sqrt{0.25n} \quad (3.5)$$

Com esses dados, basta calcular a estatística  $z$ , que é dada por:

$$z = \frac{x - \mu}{\sigma} \quad (3.6)$$

Alternativamente, pode-se subtrair uma variável da outra (i.e.  $y-z$ ) e contar o número de vezes que o sinal desta nova variável é positivo – é por isto que este teste é conhecido como *do sinal*. A vantagem dessa abordagem é simplificar o procedimento quando não se dispõe de um *software* estatístico.

O teste do sinal não é paramétrico. As duas variáveis que devem ser comparadas não precisam seguir a distribuição normal; na verdade, elas não precisam nem mesmo possuir a mesma distribuição. Essa é uma grande vantagem do teste, além de sua simplicidade e facilidade de entendimento.

### 3.5 Estimação dos modelos com erros de classificação

O vetor  $\beta$  e o parâmetro  $\alpha_1$  foram estimados utilizando-se o método de máxima verossimilhança (MV). A função de verossimilhança neste caso é da equação 2.51.

O presente estudo opta por fixar  $\alpha_0 = 0$  e estimar apenas o valor de  $\alpha_1$ . O procedimento para a estimação do coeficiente  $\alpha_1$  e do vetor  $\beta$  é maximizar a função 2.52 no *software* Stata 9.1, utilizando o método de Newton-Raphson para resolver o sistema de equações de verossimilhança, efetivamente encontrando o ponto de máximo da função. Hausman et al. (1998) explicam que a condição para a identificação dos parâmetros é  $\alpha_0 + \alpha_1 < 1$ . Caso contrário, a estimativa de  $\beta$  ficará com o sinal trocado. Essa condição certamente se aplica ao caso em questão; supondo  $\alpha_0 = 0$ , basta que pelo menos algumas empresas manipuladoras sejam descobertas para que  $\alpha_1$  seja menor do que 1.



## 4 RESULTADOS

No período entre 1998 e 2002 foram emitidos 114 AAERs para empresas que se encaixam nos critérios para a inclusão na amostra. A

Tabela 5 mostra o número de casos de fraude em cada indústria. As empresas atacadistas são as mais propensas a terem seus casos de fraudes descobertos (0,82% das demonstrações publicadas), enquanto o setor de bens de consumo duráveis não registrou nenhuma acusação de fraude durante o período em estudo.

O número de casos registrados em cada ano é mostrado na Tabela 6. O número de casos de fraude se intensificou em 1999 e 2000 (seja em números absolutos ou como proporção das demonstrações publicadas), iniciando logo após uma trajetória descendente. É importante ressaltar que é possível que alguns dos casos de fraude ocorridos em 2001 e 2002 ainda sejam descobertos, o que explicaria em parte essa diminuição.

**Tabela 5: AAERs classificados por indústria**

Indústria	AAERs	Observações	Freq. relativa
Bens de consumo não-duráveis	6	1,498	0.40%
Bens de consumo duráveis	0	630	0.00%
Manufatura	6	3,563	0.17%
Petróleo e Gás	3	1,363	0.22%
Equipamentos empresariais	41	7,572	0.54%
Telefonia	8	1,138	0.70%
Atacado	23	2,813	0.82%
Saúde	9	3,595	0.25%
Serviços públicos	4	726	0.55%
Outros	14	4,391	0.32%
Total	114	27,289	0.42%

**Tabela 6: AAERs classificados por ano**

Ano	AAERs	Observações	Freq. Relativa
1998	19	6,041	0,31%
1999	28	5,775	0,48%
2000	30	5,367	0,56%
2001	22	5,072	0,43%
2002	15	5,034	0,30%
Total	114	27,289	0,42%

#### 4.1 Descrição das variáveis

As variáveis adotadas, com base na revisão da literatura, são mostradas na Tabela 7. Ao lado de cada uma delas, são mostradas medidas de tendência central (média e mediana) e de dispersão (primeiro e terceiro quartis), calculadas para todas as observações disponíveis entre 1998 e 2002, incluindo empresas acusadas de fraude.

Algumas das variáveis possuem um número de observações muito pequeno. Isso possivelmente irá prejudicar a análise multivariada, pois os modelos não utilizarão as observações que possuem dados faltantes. Por isso, mesmo que a análise univariada aponte um determinado indicador contábil como estando relacionado às fraudes contábeis, a viabilidade do seu uso em uma análise multivariada ainda dependerá da perda de observações que ela causará no modelo final.

A comparação entre a média e a mediana das variáveis permite inferir que muitas delas não seguem uma distribuição normal. Por esse motivo, a análise univariada não poderá utilizar testes estatísticos que tenham como pressuposto a distribuição normal (por exemplo, o teste *t*). Será utilizado o teste de Wilcoxon, já explicado na metodologia.

Tabela 7: estatísticas descritivas das variáveis

Variável	N	Média	Q1	Mediana	Q3
VENAT <sub>t-1</sub>	19307	1.1912	0.5240	1.0335	1.5691
ΔVEAT <sub>t-1</sub>	10248	0.0089	-0.2173	0.0000	0.2265
CPVEN <sub>t-1</sub>	27054	2.9547	0.4780	0.6518	0.7967
ΔCPVEN <sub>t-1</sub>	25365	-0.4790	-0.0273	-0.0008	0.0275
EBITVEN <sub>t-1</sub>	18871	-4.9036	-0.0001	0.0001	0.0009
ΔEBITVEN <sub>t-1</sub>	10039	-1.1642	-0.0005	0.0000	0.0005
LLVEN <sub>t-1</sub>	20560	-4.7429	-0.0624	0.0285	0.0744
ΔLLVEN <sub>t-1</sub>	11238	-0.3364	-0.0533	-0.0006	0.0495
EBIT <sub>t-1</sub>	26331	-0.1598	-0.0820	0.0582	0.1241
ΔEBIT <sub>t-1</sub>	24461	0.0061	-0.0509	-0.0037	0.0330
ROA <sub>t-1</sub>	26332	-0.0737	-0.1214	0.0217	0.0740
ΔROA <sub>t-1</sub>	24464	0.1228	-0.0603	-0.0038	0.0378
FCL <sub>t-1</sub>	7532	1.5579	-0.1850	-0.0081	0.1334
ΔFCL <sub>t-1</sub>	3393	-0.2764	-0.2166	0.0270	0.3377
FCO <sub>t-1</sub>	7602	1.6122	-0.1243	0.0598	0.2068
ΔFCO <sub>t-1</sub>	3440	-0.2714	-0.2185	0.0227	0.3344
<b>Z<sub>t-1</sub></b>	26604	-6.6777	1.2710	2.9505	5.7050
ΔZ <sub>t-1</sub>	12978	-4.9296	-1.1390	-0.0350	0.7690
<b>ILC<sub>t-1</sub></b>	27303	3.4318	1.1721	1.9464	3.3466
ΔILC <sub>t-1</sub>	25661	-0.0732	-0.4756	-0.0272	0.3701
CXAT <sub>t-1</sub>	27944	0.2080	0.0206	0.0893	0.3222
ΔCXAT <sub>t-1</sub>	26319	-0.0011	-0.0402	-0.0007	0.0305
<b>CTAT<sub>t-1</sub></b>	27278	-0.4312	0.0408	0.2280	0.4562
ΔCTAT <sub>t-1</sub>	25634	-0.2335	-0.0742	-0.0073	0.0489
ALAV <sub>t-1</sub>	27851	1.2796	0.2767	0.4928	0.6844
ΔALAV <sub>t-1</sub>	26198	-0.0744	-0.0475	0.0031	0.0641
ALAVPATR <sub>t-1</sub>	27889	3.4204	0.2746	0.7709	1.6971
ΔALAVPATR <sub>t-1</sub>	26242	-0.1610	-0.1916	0.0087	0.2560

Tabela 7: estatísticas descritivas das variáveis - continuação

Variável	N	Média	Q1	Mediana	Q3
CRAT <sub>t-1</sub>	20903	0.1727312	0.0612132	0.1461627	0.2453
ΔCRAT <sub>t-1</sub>	11371	0.0005263	-0.0387859	0	0.0383
ESTVEN <sub>t-1</sub>	25362	0.1688	0.0063	0.0768	0.1648
ΔESTVEN <sub>t-1</sub>	23455	0.0030	-0.0070	0.0000	0.0075
ESTAT <sub>t-1</sub>	20931	0.1350529	0.0057355	0.0827915	0.2192
ΔESTAT <sub>t-1</sub>	11440	0	-0.0260483	0	0.0266
ACAT <sub>t-1</sub>	27286	0.5238	0.3056	0.5361	0.7451
ΔACAT <sub>t-1</sub>	25643	-0.0101	-0.0489	-0.0039	0.0319
AFAT <sub>t-1</sub>	27887	0.2830	0.0885	0.2012	0.4178
ΔAFAT <sub>t-1</sub>	26258	-0.0040	-0.0262	-0.0007	0.0231
RECCR <sub>t-1</sub>	20251	17.25188	4.335162	6.180645	9.2347
ΔRECCR <sub>t-1</sub>	10954	1.757188	-1.491818	0	1.5142
DJPT <sub>t-1</sub>	22143	0.0772	0.0257	0.0644	0.0997
ΔDJPT <sub>t-1</sub>	19765	0.0013	-0.0114	0.0000	0.0138
Big Four	26976	0.8273	-	-	-
ACT <sub>t-1</sub>	5796	-0.4079	-0.1485	-0.0479	0.0330
ΔACT <sub>t-1</sub>	2780	-0.3538	-0.1750	-0.0027	0.1674
ACTABS <sub>t-1</sub>	5592	3.7066	0.0446	0.1002	0.2208
ΔACTABS <sub>t-1</sub>	2618	-3.9954	-0.0936	0.0000	0.0993
MUDAUD	26976	0.1173	-	-	-
NQUAL	55760	0.3635	-	-	-

$$VENAT_t = \frac{Vendas_t}{(AT_t + AT_{t-1})/2}; CPVEN = \frac{Custo\ dos\ produtos\ vendidos}{Vendas}; EBITVEN = \frac{EBIT}{Vendas};$$

$$LLVEN = \frac{Lucro\ líquido}{Vendas}; EBITAT_t = \frac{EBIT_t}{(AT_t + AT_{t-1})/2}; ROA_t = \frac{Lucro\ líquido_t}{(AT_t + AT_{t-1})/2}; FCL =$$

$$Lucro\ líquido + Depreciação - \Delta Capital\ de\ trabalho - CAPEX; FCO =$$

$$EBIT + Depreciação - Impostos; ILC = \frac{Ativo\ corrente}{Passivo\ corrente}; CXAT = \frac{Caixa}{Ativo\ total};$$

$$CTAT = \frac{(Ativo\ corrente - Passivo\ corrente)}{Ativo\ total}; ALAV = \frac{Passivo\ Total}{Ativo\ Total}; ALAVPATR =$$

$$\frac{Passivo\ Total}{Patrimônio\ Líquido}; CRAT = \frac{Contas\ a\ receber}{Ativo\ total}; ESTVEN = \frac{Estoque}{Vendas}; ESTAT =$$

$$\frac{Estoque}{Ativo\ total}; ACAT = \frac{Ativo\ corrente}{Ativo\ total}; AFAT = \frac{Ativo\ fixo}{Ativo\ total}; RECCR = \frac{Vendas}{contas\ a\ receber};$$

$$DJPT = \frac{Despesas\ com\ juros}{Passivo\ total}; MUDAUD = mudança\ de\ auditor; NQUAL = parecer\ de$$

auditoria não-qualificado

## 4.2 Análise univariada

O objetivo da análise univariada aqui realizada é identificar os fatores que causam ou estão de alguma maneira relacionados à fraude. Isso é feito através de testes estatísticos que tenham como hipótese nula a igualdade da tendência central de dois grupos de observações – um com fraude, outro sem. Caso a hipótese nula seja rejeitada, então conclui-se que, entre as empresas acusadas, essa variável tende a ser menor ou maior do que nas outras – e, portanto, ela tem potencial para servir como indicador da ocorrência de fraudes contábeis. Para identificar as variáveis que apresentam tendência central diferente nos dois grupos, foi utilizado o teste Wilcoxon.

A Tabela 8 mostra a média e o desvio-padrão dos dois grupos de empresas (tratamento e controle). Pode-se perceber, nessa tabela, que diversas variáveis possuem médias diferentes, e algumas possuem dispersões diferentes entre os grupos. Deve-se ressaltar, porém, que a média é uma medida de tendência central bastante sujeita à influência de dados discrepantes. Como não se deseja remover esses *outliers* (pois esta discrepância em algumas observações pode ser justamente um indicador de fraude), opta-se por adotar a mediana como medida de tendência central (Tabela 9).

Na Tabela 9 também podem ser vistos os p-valores dos testes de Wilcoxon realizados. As variáveis significativas ao nível de 20% estão destacadas em negrito. Neste momento, o nível de significância adotado é bastante liberal porque não se deseja excluir do estudo variáveis que mais tarde – na análise multivariada – podem vir a ser significativas. Mesmo assim, diversas variáveis são significativas ao nível mais restrito de 10%:  $\Delta CPVEN_{t-1}$ ,  $\Delta EBIT_{t-1}$ ,  $Z_{t-1}$ ,  $ILC_{t-1}$ ,  $\Delta CXAT_{t-1}$ ,  $\Delta ACAT_{t-1}$ ,  $AFAT_{t-1}$ ,  $\Delta DJPT_{t-1}$ ,  $ACT_{t-1}$ ,  $ACTABS_{t-1}$  e  $MUDAUD$ . Dentre elas, destacam-se como altamente significativas ( $prob > |z|$  menor que 0,01) o escore  $Z$  de Altman e a mudança de auditor. Curiosamente, a variável  $Z_{t-1}$  está com sinal contrário ao esperado; a análise das medianas indica que empresas com maior  $Z$  estariam mais propensas a recorrer à fraude. Como o  $Z$  é proporcional à segurança financeira da empresa, o esperado era que a relação entre o  $Z$  e a fraude fosse inversa. Esta é, portanto, uma variável que deve ser analisada com atenção na análise multivariada.

**Tabela 8: estatísticas descritivas (média e desvio-padrão) dos grupos de tratamento e controle do estudo *matched pair***

Variável	AAER = 0		AAER = 1	
	média	dp	média	dp
VENAT <sub>t-1</sub>	1.3455	1.0341	1.5255	1.4485
ΔVENAT <sub>t-1</sub>	0.1105	0.5754	0.0084	0.4483
CPVEN <sub>t-1</sub>	0.6195	0.4835	0.5692	0.2309
ΔCPVEN <sub>t-1</sub>	-0.0977	0.7962	-0.0353	0.1543
EBITVEN <sub>t-1</sub>	-0.0422	0.9529	-0.0534	0.8601
ΔEBITVEN <sub>t-1</sub>	0.0096	0.0969	-0.1660	1.1259
LLVEN <sub>t-1</sub>	-0.2562	1.2789	-0.1869	0.8726
ΔLLVEN <sub>t-1</sub>	0.6004	3.5060	0.0696	0.8152
EBIT <sub>t-1</sub>	0.0417	0.1802	0.0553	0.1998
ΔEBIT <sub>t-1</sub>	0.0127	0.1847	0.0324	0.1761
ROA <sub>t-1</sub>	-0.0282	0.2502	-0.0265	0.2714
ΔROA <sub>t-1</sub>	0.0456	0.5226	0.0010	0.2292
FCL <sub>t-1</sub>	0.2653	0.9985	0.0171	0.2803
ΔFCL <sub>t-1</sub>	0.0847	0.7656	0.0936	0.3271
FCO <sub>t-1</sub>	0.3293	1.0148	0.0711	0.2694
ΔFCO <sub>t-1</sub>	0.1004	0.7665	0.0859	0.3313
<b>Z<sub>t-1</sub></b>	13.9059	64.9914	9.3194	20.6509
ΔZ <sub>t-1</sub>	-0.0668	2.2090	-0.8186	6.2887
<b>ILC<sub>t-1</sub></b>	2.5266	2.7812	2.7839	2.4147
ΔILC <sub>t-1</sub>	0.3788	2.4984	-0.2136	3.7147
CXAT <sub>t-1</sub>	0.1713	0.1940	0.1973	0.2302
ΔCXAT <sub>t-1</sub>	0.0163	0.1134	-0.0480	0.1814
<b>CTAT<sub>t-1</sub></b>	0.2337	0.2539	0.1904	1.0653
ΔCTAT <sub>t-1</sub>	0.0197	0.1235	-0.1302	0.9855
ALAV <sub>t-1</sub>	0.4971	0.2465	0.5586	1.0414
ΔALAV <sub>t-1</sub>	-0.0146	0.1438	0.0706	1.0197
ALAVPATR <sub>t-1</sub>	3.1966	11.5325	1.1915	1.9659
ΔALAVPATR <sub>t-1</sub>	0.8784	5.5486	-0.2881	4.3402

**Tabela 8: estatísticas descritivas (média e desvio-padrão) dos grupos de tratamento e controle do estudo *matched pair* - continuação**

Variável	AAER = 0		AAER = 1	
	média	dp	média	Dp
CRAT <sub>t-1</sub>	0.1675	0.1362	0.1690	0.1187
ΔCRAT <sub>t-1</sub>	-0.0103	0.0716	0.0011	0.0656
ESTVEN <sub>t-1</sub>	0.1012	0.1177	0.0835	0.1008
ΔESTVEN <sub>t-1</sub>	0.0021	0.0583	-0.0032	0.0579
ESTAT <sub>t-1</sub>	0.1397	0.1571	0.1580	0.1704
ΔESTAT <sub>t-1</sub>	0.0018	0.0617	-0.0111	0.0951
ACAT <sub>t-1</sub>	0.4831	0.2628	0.5403	0.2631
ΔACAT <sub>t-1</sub>	0.0052	0.0794	-0.0425	0.1768
AFAT <sub>t-1</sub>	0.2636	0.2287	0.2147	0.2025
ΔAFAT <sub>t-1</sub>	-0.0098	0.0531	-0.0061	0.0607
RECCR <sub>t-1</sub>	19.0865	54.8677	10.9863	19.5374
ΔRECCR <sub>t-1</sub>	1.7898	19.6592	1.1595	13.2941
DJPT <sub>t-1</sub>	0.0616	0.0544	0.0693	0.1002
ΔDJPT <sub>t-1</sub>	-0.0090	0.0294	0.0001	0.0298
Big Four	0.9320	-	0.9135	-
ACT <sub>t-1</sub>	-0.0453	0.1668	-0.0961	0.1264
ΔACT <sub>t-1</sub>	0.0620	0.3659	-0.2107	0.8444
ACTABS <sub>t-1</sub>	0.1048	0.2222	0.1307	0.0944
ΔACTABS <sub>t-1</sub>	-0.1443	0.2380	-0.2618	0.5940
MUDAUD	0.0583	-	0.2019	-
NQUAL	0.6058	-	0.6923	-

$VENAT_t = \frac{Vendas_t}{(AT_t + AT_{t-1})/2}$ ;  $CPVEN = \frac{Custo\ dos\ produtos\ vendidos_t}{Vendas}$ ;  $EBITVEN = \frac{EBIT}{Vendas}$ ;  
 $LLVEN = \frac{Lucro\ líquido}{Vendas}$ ;  $EBITAT_t = \frac{EBIT_t}{(AT_t + AT_{t-1})/2}$ ;  $ROA_t = \frac{Lucro\ líquido_t}{(AT_t + AT_{t-1})/2}$ ;  $FCL =$   
 $Lucro\ líquido + Depreciação - \Delta Capital\ de\ trabalho - CAPEX$ ;  $FCO = EBIT +$   
 $Depreciação - Impostos$ ;  $ILC = \frac{Ativo\ corrente}{Passivo\ corrente}$ ;  $CXAT = \frac{Caixa}{Ativo\ total}$ ;  $CTAT =$   
 $\frac{(Ativo\ corrente - Passivo\ corrente)}{Ativo\ total}$ ;  $ALAV = \frac{Passivo\ Total}{Ativo\ Total}$ ;  $ALAVPATR = \frac{Passivo\ Total}{Patrimônio\ Líquido}$ ;  
 $CRAT = \frac{Contas\ a\ receber}{Ativo\ total}$ ;  $ESTVEN = \frac{Estoque}{Vendas}$ ;  $ESTAT = \frac{Estoque}{Ativo\ total}$ ;  $ACAT =$   
 $\frac{Ativo\ corrente}{Ativo\ total}$ ;  $AFAT = \frac{Ativo\ fixo}{Ativo\ total}$ ;  $RECCR = \frac{Contas\ a\ receber}{Vendas}$ ;  $DJPT = \frac{Despesas\ com\ juros}{Passivo\ total}$ ;  
MUDAUD = mudança de auditor; NQUAL = parecer de auditoria não-qualificado

**Tabela 9:** teste de igualdade de medianas de Wilcoxon

Variável	Mediana		z	prob >  z
	AAER = 0	AAER = 1		
VENAT <sub>t-1</sub>	1.0953	1.0785	-0.62	0.5376
$\Delta$ VENAT <sub>t-1</sub>	0.0834	0.0046	0.64	0.5247
CPVEN <sub>t-1</sub>	0.6183	0.5720	0.28	0.7792
$\Delta$ CPVEN <sub>t-1</sub>	0.0035	-0.0052	1.72	0.0847
EBITVEN <sub>t-1</sub>	0.0001	0.0001	0.32	0.7486
$\Delta$ EBITVEN <sub>t-1</sub>	0.0000	-0.1660	0.23	0.8167
LLVEN <sub>t-1</sub>	0.0527	0.0234	0.19	0.8465
$\Delta$ LLVEN <sub>t-1</sub>	0.0086	-0.0058	0.06	0.9488
EBIT <sub>t-1</sub>	0.0786	0.0955	-1.21	0.2269
$\Delta$ EBIT <sub>t-1</sub>	-0.0023	0.0081	-1.69	0.0909
ROA <sub>t-1</sub>	0.0382	0.0432	-0.65	0.5144
$\Delta$ ROA <sub>t-1</sub>	0.0044	0.0035	-0.47	0.6375
FCL <sub>t-1</sub>	-0.0053	-0.0106	0.69	0.4922
$\Delta$ FCL <sub>t-1</sub>	-0.0438	0.0530	-0.86	0.3909
FCO <sub>t-1</sub>	0.0899	0.0711	0.72	0.4694
$\Delta$ FCO <sub>t-1</sub>	-0.0238	0.0375	-0.40	0.6909
<b>Z</b> <sub>t-1</sub>	3.3480	5.0550	-2.72	0.0066
$\Delta$ Z <sub>t-1</sub>	-0.1010	-0.2770	1.02	0.3079
<b>ILC</b> <sub>t-1</sub>	1.7631	2.1981	-1.75	0.0807
$\Delta$ ILC <sub>t-1</sub>	-0.0146	0.0241	-0.02	0.9872
CXAT <sub>t-1</sub>	0.0969	0.0851	-0.19	0.8517
$\Delta$ CXAT <sub>t-1</sub>	0.0004	-0.0080	2.24	0.0251
<b>CTAT</b> <sub>t-1</sub>	0.2335	0.2452	-1.52	0.1290
$\Delta$ CTAT <sub>t-1</sub>	-0.0004	0.0012	0.99	0.3243
ALAV <sub>t-1</sub>	0.4864	0.4864	0.60	0.5484
$\Delta$ ALAV <sub>t-1</sub>	0.0004	-0.0067	1.05	0.2938
ALAVPATR <sub>t-1</sub>	0.9333	0.7633	1.26	0.2085
$\Delta$ ALAVPATR <sub>t-1</sub>	0.0019	-0.0333	0.91	0.3637

**Tabela 9:** teste de igualdade de medianas de Wilcoxon - continuação

Variável	Mediana		z	prob >  z
	AAER = 0	AAER = 1		
CRAT <sub>t-1</sub>	0.1205	0.1498	-0.43	0.6644
ΔCRAT <sub>t-1</sub>	0.0004	-0.0002	-0.86	0.3917
ESTVEN <sub>t-1</sub>	0.0680	0.0547	0.86	0.3880
ΔESTVEN <sub>t-1</sub>	0.0000	-0.0032	0.00	1.0000
ESTAT <sub>t-1</sub>	0.0624	0.0960	0.49	0.6277
ΔESTAT <sub>t-1</sub>	0.0000	0.0000	-0.39	0.6995
ACAT <sub>t-1</sub>	0.5083	0.5520	-1.51	0.1316
ΔACAT <sub>t-1</sub>	0.0079	-0.0076	2.04	0.0414
AFAT <sub>t-1</sub>	0.1893	0.1585	1.72	0.0850
ΔAFAT <sub>t-1</sub>	-0.0012	0.0002	-1.26	0.2096
RECCR <sub>t-1</sub>	5.7828	5.2251	1.00	0.3180
ΔRECCR <sub>t-1</sub>	0.0405	-0.0231	0.73	0.4677
DJPT <sub>t-1</sub>	0.0557	0.0517	-0.37	0.7136
ΔDJPT <sub>t-1</sub>	-0.0086	-0.0007	-1.95	0.0518
Big Four	-	-	0.50	0.6176
ACT <sub>t-1</sub>	-0.0141	-0.0816	1.77	0.0761
ΔACT <sub>t-1</sub>	-0.0142	0.0641	-0.27	0.7848
ACTABS <sub>t-1</sub>	0.0431	0.0975	-2.48	0.0132
ΔACTABS <sub>t-1</sub>	-0.0433	-0.0062	-0.17	0.8690
MUDAUD	-	-	-3.06	0.0022
NQUAL	-	-	-1.30	0.1921

$$VENAT_t = \frac{Vendas_t}{(AT_t + AT_{t-1})/2}; CPVEN = \frac{Custo\ dos\ produtos\ vendidos_t}{Vendas}; EBITVEN = \frac{EBIT_t}{Vendas};$$

$$LLVEN = \frac{Lucro\ líquido_t}{Vendas}; EBITAT_t = \frac{EBIT_t}{(AT_t + AT_{t-1})/2}; ROAt = \frac{Lucro\ líquido_t}{(AT_t + AT_{t-1})/2}; FCL =$$

$$Lucro\ líquido + Depreciação - \Delta Capital\ de\ trabalho - CAPEX; FCO = EBIT +$$

$$Depreciação - Impostos; ILC = \frac{Ativo\ corrente}{Passivo\ corrente}; CXAT = \frac{Caixa}{Ativo\ total}; CTAT =$$

$$\frac{(Ativo\ corrente - Passivo\ corrente)}{Ativo\ total}; ALAV = \frac{Passivo\ Total}{Ativo\ Total}; ALAVPATR = \frac{Passivo\ Total}{Patrimônio\ Líquido};$$

$$CRAT = \frac{Contas\ a\ receber}{Ativo\ total}; ESTVEN = \frac{Estoque}{Vendas}; ESTAT = \frac{Estoque}{Ativo\ total}; ACAT =$$

$$\frac{Ativo\ corrente}{Ativo\ total}; AFAT = \frac{Ativo\ fixo}{Ativo\ total}; RECCR = \frac{Despesas\ com\ juros}{Contas\ a\ receber}; DJPT = \frac{Despesas\ com\ juros}{Passivo\ total};$$

MUDAUD = mudança de auditor; NQUAL = parecer de auditoria não-qualificado

Existem outras variáveis que apontam para uma relação positiva entre segurança financeira e fraude, ao contrário do esperado. São elas:  $\Delta CPVEN_{t-1}$ ,  $\Delta EBIT_{t-1}$  e  $ILC_{t-1}$ . As duas primeiras raramente são utilizadas na literatura, pois são obtidas através do operador de diferenças. Quanto ao índice de liquidez corrente, os resultados aqui encontrados vão de encontro à literatura pesquisada, que aponta para a insignificância da variável.

Para verificar se estes achados são robustos, deve-se utilizar estas variáveis em uma análise multivariada – o que será feito a seguir, após a apresentação dos resultados do modelo de Jones.

### 4.3 Modelo de Jones

É normal que as empresas tenham despesas de depreciação e outros componentes não-financeiros em seus resultados, sem que isso signifique que ela esteja gerenciando seus resultados. Por isso, pode-se falar em *accruals* esperados (não-discricionários), que são consequência natural da situação econômico-financeira da empresa. De acordo com o modelo de Jones, os *accruals* esperados dependem do ativo permanente e da variação das receitas da empresa. Em um modelo com efeitos aleatórios, a equação é:

$$AT_{it} = \alpha + \beta_1 \Delta vendas_{it} + \beta_2 AP_{it} + v_i + \varepsilon_{it} \quad (3.7)$$

sendo que  $v_i$  é o componente que captura os choques que afetam apenas a empresa  $i$  ao longo de todo o período da amostra. Os resultados dessa regressão são mostrados na Tabela 10.

Para verificar se o modelo com efeitos aleatórios é realmente o mais adequado, foi utilizado o teste de especificação de Hausman (1978). Considerou-se que o estimador utilizado no modelo de efeitos fixos (MQO) é consistente em qualquer situação, e o estimador utilizado no modelo de efeitos aleatórios (GLS) é consistente e eficiente apenas sob a hipótese que será testada ( $H_0$ ). Os resultados são mostrados na Tabela 11. A hipótese nula não é rejeitada. Verifica-se, portanto, que as diferenças entre os dois coeficientes não são sistemáticas, e o estimador GLS é consistente e eficiente. É por esse motivo que se adota o modelo de efeitos aleatórios.

**Tabela 10: regressão do modelo de Jones**

Variável dependente: AT				
Observações: 2699				
Grupos: 382				
Período: 1996-2008				
Variável	Coef.	Erro Padrão Jackknife	z	P> z
Constante	-0.0327	0.006140	-5.33	0.000
$\Delta$ Vendas	0.0468	0.007468	6.27	0.000
AP	-0.0321	0.010254	-3.14	0.002
R <sup>2</sup> within: 0.0138				
R <sup>2</sup> between: 0.0269				
R <sup>2</sup> overall: 0.0195				

**Tabela 11: teste de especificação de Hausman**

Variável	Coef.	
	OLS	GLS
$\Delta$ Vendas	0.0450	0.0468
AP	-0.0282	-0.0321
$\chi^2$ : 0.57		
Prob > $\chi^2$ : 0.7512		

A regressão do modelo de Jones possui resíduos autocorrelacionados e heterocedásticos. Deve-se notar que, mesmo assim, os resíduos do MQO convergem assintoticamente aos erros correspondentes, desde que o modelo esteja corretamente especificado (DAVIDSON; MacKINNON, 1999). Como o objetivo da regressão é utilizar os resíduos como estimativa dos *accruals* discricionários, não há necessidade de nenhum procedimento especial para corrigir a regressão. É também por esse motivo que não são apresentados os resultados de nenhum teste de detecção de heterocedasticidade.

#### 4.4 Análise multivariada

A análise multivariada foi baseada em modelos *probit* com e sem erros de classificação, considerando-se duas possibilidades de amostras: uma apenas com as empresas constantes na análise univariada (grupos de tratamento e de controle) e outra com todas as empresas da população.

O objetivo dos modelos apenas com a amostra da análise univariada é possibilitar resultados comparáveis com os de estudos anteriores. Ao usar toda a amostra, porém, utilizam-se todos os dados disponíveis, obtendo-se coeficientes mais próximos daqueles que seriam utilizados caso o modelo fosse aplicado na detecção de fraudes.

##### 4.4.1 Modelo *probit, matched pair*

O primeiro passo foi selecionar as variáveis que tiveram suas hipóteses nulas rejeitadas no teste de Wilcoxon ao nível de significância de 20%. Optou-se por um  $\alpha$  bastante liberal com o objetivo de evitar a exclusão de variáveis que eventualmente seriam significativas em uma análise multivariada.

É importante observar que nem todas as variáveis podem ser incluídas em um modelo *probit*. Um dos motivos é o baixo de número de observação; isso fez com que as variáveis referentes aos *accruals* discricionários fossem descartadas. Outro motivo é a existência de correlação entre alguns pares de variáveis. A Tabela 12 mostra uma matriz de correlações reduzida, apenas com os pares de variáveis que tiveram um coeficiente de correlação superior a 0,20 (com exceção dos *accruals*). Como deseja-se também estimar um modelo com erros de classificação utilizando toda a amostra, essa matriz foi criada utilizando-se todos os dados disponíveis entre 1998 e 2002, excluindo-se empresas financeiras. Devido à correlação, foram removidas as variáveis  $CTAT_{t-1}$ ,  $ACAT_{t-1}$  e  $\Delta ACAT_{t-1}$ . Com este procedimento, evita-se que a multicolinearidade cause problemas ao modelo *probit*.

Tabela 12: matriz de correlações das variáveis que tiveram coeficiente de correlação superior a 0,2

	$Z_{t-1}$	$ILC_{t-1}$	$\Delta CXAT_{t-1}$	$CTAT_{t-1}$	$ACAT_{t-1}$	$\Delta ACAT_{t-1}$	$AFAT_{t-1}$
$Z_{t-1}$	1.00						
$ILC_{t-1}$	0.04	1.00					
$\Delta CXAT_{t-1}$	-0.04	0.09	1.00				
$CTAT_{t-1}$	0.78	0.01	-0.02	1.00			
$ACAT_{t-1}$	-0.03	0.18	0.21	-0.02	1.00		
$\Delta ACAT_{t-1}$	-0.06	0.07	0.72	-0.05	0.24	1.00	
$AFAT_{t-1}$	0.02	-0.13	-0.09	0.01	-0.72	-0.06	1.00

As variáveis escolhidas foram utilizadas em um modelo *probit* tradicional (isto é, que adota o pressuposto de que  $\alpha_0 = \alpha_1 = 0$ ) apenas com as observações das empresas que fraudaram e do grupo de controle. O modelo obtido é mostrado na Tabela 13. Foram utilizadas apenas 132 observações devido a valores faltantes nas variáveis independentes. O teste de razão de verossimilhança não é capaz de rejeitar a hipótese nula de que não há nenhuma relação entre as variáveis independentes e a fraude contábil (detectada) ao nível de 10%.

Neste modelo, apenas a variável *MUDAUD* é significativa e possui o sinal esperado. Isso indica que, quando uma empresa muda de auditor, as primeiras demonstrações financeiras auditadas pela nova firma têm maior probabilidade de serem acusadas de fraude. Esse coeficiente é significativo a 5%. Deve-se ressaltar que não é possível determinar se (a) as firmas de auditoria descobriram a fraude e rescindiram o contrato ou (b) o término do contrato criou a oportunidade para que os gestores recorressem à fraude.

É preciso melhorar o modelo através da exclusão de variáveis irrelevantes. Isso pode ser feito através de um procedimento *stepwise*, que consiste em remover a variável menos significativa (com maior p-valor) e rodar novamente o modelo, repetindo o procedimento até que todos os coeficientes sejam significativos a 10%. O modelo resultante passou a rejeitar a hipótese nula do teste de razão de verossimilhança a 1%, mantendo praticamente o mesmo pseudo  $R^2$  (Tabela 14).

Agora, a variação do caixa em relação ao ativo total ( $\Delta CXAT_{t-1}$ ) passou a ser significativa. Essa variável está negativamente relacionada com a probabilidade de fraude no ano subsequente, e seu coeficiente é significativo a 1%. Isso indica que empresas que tiveram um desencaixe acentuado têm maior probabilidade de fraudarem suas demonstrações financeiras. Isso condiz com a necessidade que essas empresas têm de captar recursos rapidamente, seja no mercado de capitais ou através de empréstimos.

**Tabela 13: modelo *probit matched pair***


---

Variável dependente: AAER  
 Observações: 132  
 Período: 1998-2002

---

Variável	Coef.	Erro Padrão	z	P> z
constante	-0,3109	0,3399	-0,91	0,360
$\Delta$ CPVEN <sub>t-1</sub>	0,5085	1,0135	0,50	0,616
$\Delta$ EBIT <sub>t-1</sub>	0,0762	0,8177	0,09	0,926
Z <sub>t-1</sub>	0,0010	0,0083	0,13	0,900
ILC <sub>t-1</sub>	0,0634	0,0795	0,80	0,425
$\Delta$ CXAT <sub>t-1</sub>	-1,7685	1,2614	-1,40	0,161
AFAT <sub>t-1</sub>	-0,1069	0,5756	-0,19	0,853
$\Delta$ DJPT <sub>t-1</sub>	4,6184	4,0998	1,13	0,260
MUDAUD	0,7268	0,3652	1,99	0,047
NQUAL	0,1020	0,2413	0,42	0,672

---

LR  $\chi^2$ : 13,17  
 Prob >  $\chi^2$ : 0,1553  
 Log Likelihood: -84,78  
 Pseudo R<sup>2</sup>: 0,0721

---

**Tabela 14: modelo *probit matched pair* após procedimento *stepwise***

Variável dependente: AAER  
 Observações: 186  
 Período: 1998-2002

---

Variável	Coef.	Erro Padrão	z	P> z
constante	-0,0712	0,1009	-0,71	0,480
$\Delta$ CXAT <sub>t-1</sub>	-2,0039	0,6966	-2,88	0,004
MUDAUD	0,9206	0,3052	3,02	0,003

---

LR  $\chi^2$ : 18,57  
 Prob >  $\chi^2$ : 0,0001  
 Log Likelihood: -119,37  
 Pseudo R<sup>2</sup>: 0,0722

---

4.4.2 Modelo *probit* completo

As variáveis escolhidas também foram utilizadas em um modelo *probit* tradicional com todas as observações disponíveis no período em estudo. O resultado é mostrado na Tabela 15. Pode-se perceber que, com esta metodologia, apenas as variáveis  $\Delta CXAT(t-1)$  e  $AFAT(t-1)$  são significativas. A variável *MUDAUD* perdeu significância.

**Tabela 15: modelo *probit* com todas as observações**

Variável	Coef.	Erro Padrão	z	P> z
constante	-2.3838	0.1096	-21.75	0.000
$\Delta CPVEN_{t-1}$	0.0000	0.0007	0.03	0.973
$\Delta EBIT_{t-1}$	0.0428	0.1006	0.43	0.671
$Z_{t-1}$	0.0006	0.0005	1.31	0.190
$ILC_{t-1}$	-0.0272	0.0199	-1.37	0.172
$\Delta CXAT_{t-1}$	-0.6016	0.3365	-1.79	0.074
$AFAT_{t-1}$	-0.4926	0.2023	-2.44	0.015
$\Delta DJPT_{t-1}$	0.0510	0.3789	0.13	0.893
<i>MUDAUD</i>	0.1132	0.1118	1.01	0.311
<i>NQUAL</i>	-0.1224	0.0893	-1.37	0.171

LR  $\chi^2$ : 14,59  
 Prob >  $\chi^2$ : 0,103  
 Log Likelihood: -435,62  
 Pseudo R<sup>2</sup>: 0,0165

A variável  $AFAT_{t-1}$ , que no modelo anterior não era significativa, passa a rejeitar a hipótese nula ao nível de 5%. Seu sinal é negativo, o que indica que empresas acusadas de fraude possuem menos ativos fixos que as outras. Considerando-se que são esses ativos que geram as receitas da companhia (pois são fábricas ou equipamentos), pode-se interpretar esse coeficiente como um indicador de que as empresas que não fraudaram estavam em melhor situação para gerar receitas no futuro. As empresas acusadas, por outro lado, podem ter recorrido à

fraude justamente para obter os recursos necessários para investir nos ativos que seus gestores julgavam necessários para garantir sua competitividade.

Após o procedimento *stepwise*, esse modelo obteve uma ajuste bem melhor, rejeitando a  $H_0$  do teste de razão de verossimilhança ao nível de 1% (Tabela 16). A variável  $ILC_{t-1}$ , apesar de não ser significativa a 10%, foi mantida no modelo por melhorar o ajuste do modelo como um todo, contribuindo para a elevação do LR  $\chi^2$ .

**Tabela 16: modelo *probit* com todas as observações, após procedimento *stepwise***

Variável	Coef.	Erro Padrão	z	P> z
Constante	-2,4804	0,0721	-34,40	0,000
$ILC_{t-1}$	-0,0172	0,0122	-1,41	0,158
$\Delta CXAT_{t-1}$	-0,5950	0,2117	-2,81	0,005
$AFAT_{t-1}$	-0,5756	0,1764	-3,26	0,001
MUDAUD	0,1948	0,0890	2,19	0,029

LR  $\chi^2$ : 25,97  
 Prob >  $\chi^2$ : 0,000  
 Log Likelihood: -620,71  
 Pseudo R<sup>2</sup>: 0,0205

#### 4.4.3 Modelo com erros de classificação

Os modelos analisados anteriormente já permitiram compreender parcialmente as causas da fraude, porém não estão corretamente especificados. Restringindo  $\alpha_0 = 1$ , mas inserindo no modelo o coeficiente  $\alpha_1$ , obteve-se a especificação apresentada na Tabela 17.

**Tabela 17: modelo *probit* com erros de classificação**


---

Variável dependente: AAER  
 Observações: 16899  
 Período: 1998-2002

---

Variável	Coef.	Erro Padrão	z	P> z
constante	-0.8325	1.1451	-0.73	0,467
$\Delta\text{CPVEN}_{t-1}$	0.0000	0.0014	0.03	0,977
$\Delta\text{EBIT}_{t-1}$	0.1275	0.4161	0.31	0,759
$Z_{t-1}$	0.0084	0.0067	1.25	0,211
$\text{ILC}_{t-1}$	-0.0611	0.0410	-1.49	0,136
$\Delta\text{CXAT}_{t-1}$	-0.8498	0.6794	-1.25	0,211
$\text{AFAT}_{t-1}$	-0.8242	0.4827	-1.71	0,088
$\Delta\text{DJPT}_{t-1}$	0.0849	0.6967	0.12	0,903
MUDAUD	0.1970	0.2177	0.91	0,365
NQUAL	-0.2556	0.2095	-1.22	0,222
$\alpha_1$	0.9563	0.0702	13.63	0,000

---

Wald  $\chi^2$ : 4,64  
 Prob >  $\chi^2$ : 0,8644  
 Log Likelihood: -434,41

---

Nesse modelo, apenas a variável  $\text{AFAT}_{t-1}$  é significativa, mantendo o mesmo sinal do modelo sem erros de classificação. O teste de Wald (que é uma alternativa ao teste de razão de verossimilhança<sup>16</sup>) não rejeita a hipótese nula de que todos os coeficientes são iguais a zero. O procedimento *stepwise* é utilizado para melhorar o modelo, revelando diversas variáveis significativas (Tabela 18).

---

<sup>16</sup> Engle (1984) demonstrou que o teste de Wald e o teste de razão de verossimilhança são assintoticamente equivalentes.

**Tabela 18: modelo com erros de classificação após procedimento *stepwise***

Variável dependente: AAER

Observações: 22841

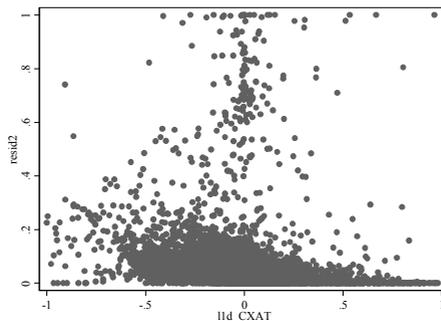
Período: 1998-2002

Variável	Coef.	Erro Padrão	z	P> z
constante	-0.6826	0.5157	-1.32	0,186
$Z_{t-1}$	0.0123	0.0070	1.76	0,079
$ILC_{t-1}$	-0.0700	0.0337	-2.08	0,038
$\Delta CXAT_{t-1}$	-1.0099	0.4828	-2.09	0,036
$AFAT_{t-1}$	-1.0715	0.3963	-2.70	0,007
MUDAUD	0.4411	0.2332	1.89	0,059
$\alpha_1$	0.9726	0.0179	54.19	0,000

Wald  $\chi^2$ : 12,94Prob >  $\chi^2$ : 0,0239

Log Likelihood: -616,59

Nesta nova especificação, existem cinco variáveis significativas. Mas, antes que seja possível interpretar os resultados, é preciso verificar se o modelo apresenta resíduos homocedásticos. Para isso, foi feita uma inspeção visual. A presença de heterocedasticidade é bastante evidente, como pode-se perceber na Figura 5. Verifica-se que a dispersão dos resíduos quadrados é maior quando  $\Delta CXAT_{t-1}$  é próximo de zero. Esse problema motivou a adoção de erros robustos, e o modelo resultante é mostrado na Tabela 19.

**Figura 5: *scatterplot* dos resíduos quadrados contra  $\Delta CXAT_{(t-1)}$**

As variáveis significativas são basicamente as mesmas do modelo *probit* com a amostra completa (Tabela 16); apenas  $ILC_{t-1}$ , que antes não era significativa, passou a ser. Isso indica que possivelmente a estatística  $z$  do modelo anterior estava enviesada devido aos erros de classificação. Além disso, os valores dos coeficientes mudaram significativamente.

**Tabela 19: modelo *probit* com erros de classificação e erros robustos**

Variável dependente: AAER

Observações: 22841

Período: 1998-2002

Variável	Coef.	Erro Padrão	Z	P> z
		Robusto		
constante	-0.6826	0.3442	-1.98	0,047
$Z_{t-1}$	0.0123	0.0125	0.98	0,325
$ILC_{t-1}$	-0.0700	0.0388	-1.80	0,071
$\Delta CXAT_{t-1}$	-1.0099	0.3935	-2.57	0,010
$AFAT_{t-1}$	-1.0715	0.3326	-3.22	0,001
MUDAUD	0.4411	0.2301	1.92	0,055
$\alpha_1$	0.9726	0.0128	76.08	0,000

Wald  $\chi^2$ : 27,62  
 Prob >  $\chi^2$ : 0,0000  
 Log Likelihood: -616,59

Como o modelo final apresentou resíduos heterocedásticos, o procedimento *stepwise* foi repetido utilizando-se apenas modelos com erros robustos (Tabela 20). O resultado final agora inclui a variável *NQUAL*, que é uma novidade neste modelo. O sinal negativo é teoricamente adequado, indicando que as empresas que obtiveram pareceres de auditoria sem restrições são menos propensas à fraude. A variável  $Z_{t-1}$  continua no modelo porque contribui para a melhoria do ajuste, mesmo tendo o sinal contrário ao esperado. Esse é considerado o modelo final, isto é, que possui a melhor especificação possível dentro dos objetivos desta dissertação.

**Tabela 20: modelo final após *stepwise* com erros robustos**

Variável dependente: AAER

Observações: 22841

Período: 1998-2002

Variável	Coef.	Erro Padrão	z	P> z
	Robusto			
constante	-0.3357	0.4441	-0.76	0.450
$Z_{t-1}$	0.0148	0.0117	1.26	0.206
$ILC_{t-1}$	-0.0755	0.0353	-2.14	0.032
$\Delta CXAT_{t-1}$	-1.0061	0.4123	-2.44	0.015
$AFAT_{t-1}$	-1.1501	0.3751	-3.07	0.002
MUDAUD	0.4511	0.2440	1.85	0.065
NQUAL	-0.3147	0.1898	-1.66	0.097
$\alpha_1$	0.9761	0.0105	92.61	0.000

Wald  $\chi^2$ : 34,06Prob >  $\chi^2$ : 0,0000

Log Likelihood: -614,87

É interessante observar que a variável  $Z_{t-1}$ , altamente significativa na análise univariada, perdeu significância no modelo com erros de classificação e erros robustos. Isso indica que essa variável, na realidade, não é relevante para a detecção de fraudes nas demonstrações financeiras. Nos modelos anteriores, sua aparente significância possivelmente deve-se a dois fatores: (a) heterocedasticidade nos resíduos; (b) especificação incorreta dos modelos devido a erros de classificação.

Em termos de número de variável e significância, o modelo final é bastante similar ao modelo sem erros de classificação. A principal mudança é a inclusão da variável  $NQUAL$ , que possui coeficiente positivo. Pode-se interpretar essa variável como indicando que demonstrações com pareceres de auditoria sem ressalvas estão menos propensos a serem fraudulentos – o que é coerente com o senso comum.

As variáveis  $AFAT_{t-1}$  e  $MUDAUD$  mantiveram seus coeficientes e continuam significativas. É importante observar que a variável  $ILC_{t-1}$  mudou de sinal em relação à análise univariada, sendo significativa a 10%. Isso permite compatibilizar a interpretação desta variável com a

explicação já oferecida para o sinal de  $CXAT_{t-1}$ . Assim, as empresas que fraudam suas demonstrações não têm apenas um desencaixe significativo, como também possuem menor liquidez.

É interessante observar que muitas variáveis passaram a ser significativas. Há uma explicação para isso: na análise univariada, o objetivo era identificar variáveis que explicam a ocorrência de fraude. Os modelos anteriores, porém, não buscam estimar a probabilidade de fraude, mas sim a probabilidade de fraude multiplicada pela probabilidade de *detecção* da fraude. Ao estimar os erros de classificação, o modelo torna-se mais adequado às variáveis que foram escolhidas anteriormente. Todos os coeficientes significativos do modelo final com erros robustos, após procedimento *stepwise* (Tabela 20), têm o sinal que é esperado de acordo com a teoria e a intuição.

A constante  $\alpha_1$  é igual a 0,9761. Ou seja, estima-se que 97,26% dos casos de fraude ocorridos entre 1998 e 2002 não tenham sido detectados pela SEC. O erro padrão robusto estimado para esse coeficiente é baixo quando comparado ao próprio parâmetro estimado (0,0128) – o que indica que se pode rejeitar, com *prob* > z igual a zero até a quarta casa decimal, a hipótese nula de que não existem erros de classificação na variável dependente. Ressalva-se que o p-valor reportado na tabela, apesar da coluna informar que se trata de *prob* > |z|, é unilateral – já que  $\alpha_1$  não pode ser negativo. Isso não traz maiores consequências práticas, já que neste caso o p-valor é extremamente baixo em qualquer caso.

O modelo como um todo é altamente significativo, rejeitando a  $H_0$  do teste de Wald com p-valor igual a zero até a quarta casa decimal. Isso indica que é possível relacionar a variável dependente às independentes através de um modelo não-linear baseado na função *probit*, levando-se em conta os erros de classificação.

## 5 CONCLUSÃO

O primeiro passo deste trabalho foi verificar o comportamento dos estimadores usualmente utilizados em uma situação próxima daquela verificada no estudo de fraudes nas demonstrações financeiras. Esse objetivo foi alcançado através de um experimento de Monte Carlo. A importância dessa análise deve-se principalmente ao fato da variável dependente normalmente utilizada em modelos de identificação e previsão de FDF (os AAERs) ter características singulares, notadamente a presença de erros de classificação bastante significativos.

O estudo de Monte Carlo confirmou a existência de inconsistências em modelos *probit*, causadas pelo erro de classificação  $\alpha_1$ . Por isso, em relação ao primeiro par de hipóteses de pesquisa, rejeita-se a hipótese nula de que uma especificação *probit* tradicional é consistente na presença de erros de classificação (Quadro 2).

Também verificou-se que o estimador proposto por Hausman et al. (1998) é inconsistente em alguns casos – especificamente, quando os erros de classificação são altos. Por isso, rejeita-se a hipótese nula do segundo par de hipóteses, que postula que o estimador proposto com Hausman et al. é consistente na presença de uma elevada proporção de erros de classificação na variável dependente. Apesar disso, seu uso apresenta vieses menores que os de um modelo *probit* tradicional,

A estimativa de  $\alpha_1$  obtida através da especificação proposta por Hausman et al. não é enviesada mesmo quando o verdadeiro valor de  $\alpha_1$  está entre 0,90 e 0,99. Por isso, não se rejeita a hipótese nula do terceiro teste proposto na introdução deste trabalho, que postula que o estimador  $\hat{\alpha}_1$  é igual ao verdadeiro valor de  $\alpha_1$ . Com isso, completa-se o primeiro objetivo do trabalho, referente ao experimento de Monte Carlo.

O segundo passo foi realizar uma análise univariada, que revelou a existência de diversas variáveis que apresentam correlação significativa (de acordo com o teste de Wilcoxon) com a presença de fraude nas demonstrações financeiras. Apesar de não permitir conclusões substanciais, esse objetivo específico ajudou na seleção de variáveis para a análise multivariada.

O modelo final, mostrado na Tabela 20, é corrigido para heterocedasticidade através do estimador sanduíche de White (1980). Isso não garante que os erros-padrões estejam corretos, mas permite que se tenha uma estimativa mais confiável. Ele apresenta cinco variáveis com coeficientes significativos, todos eles com o sinal esperado.

Também pode-se inferir que  $\alpha_1$  é maior do que 0, rejeitando-se assim a hipótese nula do quarto par de hipóteses de pesquisa.

Por fim, o modelo final apresenta estatística de Wald igual a 34,06; rejeita-se portanto a hipótese nula de que todos os coeficientes do modelo são iguais a zero em favor da hipótese de que existe uma relação significativa entre a variável dependente e as independentes.

**Quadro 2:** hipóteses e conclusões

Hipótese	Conclusão
$H_0: \hat{\beta}_y = \beta_y$ $H_1: \hat{\beta}_y \neq \beta_y$	O estimador <i>probit</i> usualmente utilizado é inconsistente na presença de erros de classificação. Rejeita-se $H_0$ .
$H_0: \gamma_{\hat{y}} = \beta_y$ $H_1: \gamma_{\hat{y}} \neq \beta_y$	O estimador <i>probit</i> proposto por Hausman et al. (1998), com correção para erros de classificação, é inconsistente quando $0,90 \leq \alpha_1 \leq 0,99$ , mas o viés é atenuado. Rejeita-se $H_0$ .
$H_0: \hat{\alpha}_1 = \alpha_1$ $H_1: \hat{\alpha}_1 \neq \alpha_1$	Não é possível afirmar que as estimativas de $\alpha_1$ obtidas são inconsistentes. Não se rejeita $H_0$ .
$H_0: \alpha_1 \leq 0$ $H_1: \alpha_1 > 0$	Estima-se que o valor de $\alpha_1$ , no período de estudo, era de 97,61%. Rejeita-se $H_0$ .
$H_0: \hat{\beta} = 0$ $H_1: \hat{\beta} \neq 0$	É possível relacionar a variável dependente com a matriz <b>X</b> selecionada. Rejeita-se $H_0$ .

Verificou-se que a variável  $ILC_{t-1}$  é significativa e possui coeficiente negativo, o que vai de encontro a estudos similares que apontam para a insignificância dessa variável (BENEISH, 1999b; KIRKOS ET AL., 2007). Esse resultado diferente pode ser consequência da metodologia diferente empregada neste trabalho, já que a variável não é estatisticamente diferente de zero quando utilizada em um modelo *probit* normal.

As variáveis  $NQUAL$ ,  $\Delta CXAT_{t-1}$  e  $AFAT_{t-1}$  não são comuns na literatura. Foi encontrado apenas um estudo em que  $AFAT_{t-1}$  não foi significativamente diferente de zero (KIRKOS ET AL., 2007).

Quanto à mudança de auditor ( $MUDAUD$ ), os resultados deste trabalho corroboram os achados de Ettredge et al. (2008), que obtiveram uma relação positiva e significativa entre essa variável e a fraude.

De maneira geral, os resultados indicam que é possível estimar um modelo *probit* com erros de classificação para identificar fraudes em

empresas americanas, apesar de não terem sido encontrados trabalhos similares que utilizem esse procedimento. Apenas os *working papers* de Wang (2004 e 2008) trabalham nesse mesmo sentido, porém adotando uma metodologia diferente para estimar a probabilidade de erro.

Recomenda-se cautela no uso de modelos de escolha binária não-corrigidos como ferramenta de apoio à detecção de fraudes. Idealmente, deve-se utilizar uma especificação que leve em consideração os erros de classificação para que sejam obtidos estimadores melhores. Adicionalmente, é importante aumentar a sensibilidade dos modelos de forma a identificar um maior número de casos suspeitos, de acordo com o  $\alpha_1$  estimado. Isso contribuirá para diminuir o número de fraudes não-detectadas.

O pressuposto de ausência de correlação entre as variáveis independentes e a probabilidade de erro de classificação é bastante forte. Na realidade, espera-se que as empresas que têm suas fraudes detectadas tenham características significativamente diferentes daquelas que escapam. Este é um dos pontos que podem ser trabalhados em estudos futuros.

Para trabalhos futuros, é importante melhorar o estimador utilizado nesta dissertação. Não foi possível descobrir a origem da inconsistência observada no experimento de Monte Carlo; é possível que seja decorrente de detalhes operacionais – isto é, da programação do estimador de máxima verossimilhança. O fato de ocasionalmente o estimador não ser capaz de alcançar a convergência pode estar causando estes vieses, já que as estatísticas reportadas são construídas com base apenas nos casos em que o estimador foi capaz de convergir.

A replicação do estudo em empresas brasileiras depende de avanços metodológicos na construção da variável dependente. Por isso, outra possibilidade para trabalhos futuros é o desenvolvimento de técnicas que tornem este modelo aplicável ao caso brasileiro. A existência de erros do tipo  $\alpha_0$  faz com que não seja possível utilizar as republicações ordenadas pela CVM como *proxy* para a ocorrência de fraude: como foi observado no caso norte-americano, o erro do tipo  $\alpha_1$  é substancial, e basta apenas algumas empresas incorretamente classificadas como culpadas para que as premissas do modelo não sejam satisfeitas. É preciso, pois, compilar manualmente e com cuidado ímpar a lista de empresas que emitiram demonstrações financeiras fraudulentas. Isso pode ser feito com o auxílio das próprias republicações, aliada a uma análise das notícias publicadas na imprensa

– sempre com o cuidado de selecionar apenas casos confirmados de fraude.

Este trabalho também abre portas para estudos que analisem a evolução da proporção de fraudes não detectadas. É possível utilizar um coeficiente de erro ( $\alpha_1$ ) para cada ano em estudo e realizar testes para verificar se a eficiência da SEC (ou da CVM) na detecção de fraudes está aumentando ou diminuindo. Assim, é possível associar o combate às fraudes com fatores políticos, econômicos e sociais. Com esta metodologia, pode-se estudar não apenas a fraude em si, como também a sua detecção, criando possibilidades para novos estudos que tragam um enfoque diferente a este tema.

## REFERÊNCIAS BIBLIOGRÁFICAS

ABBOTT, L. J.; PARK, Y.; PARKER, S. The effects of audit committee activity and independence on corporate fraud. **Managerial Finance**, 2000.

AKTAS, R.; ALP, A.; DOGANAY, M. M. Towards predicting financial information manipulation. **The ICAI Journal of Applied Finance**, v. 13, n. 7, p. 39-52, 2007.

ALTMAN, E. I. Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. **The Journal of Finance**, v. 23, n. 4, p. 589-609, 1968.

AMEMIYA, Takeshi. Qualitative response models: a survey. **Journal of Economic Literature**, v. 19, n. 4, p. 1483-1536, dec. 1981.

ANDERSON, D. R.; SWEENEY, D. J.; WILLIAMS, T. A. **Statistics for Business and Economics**. 6. ed. St. Paul: West, 1996.

ARTÍS, Manuel; AYUSO, Mercedes; GUILLÉN, Montserrat. Detection of automobile insurance fraud with discrete choice models and misclassified claims. **The Journal of Risk and Insurance**, v. 69, n. 3, p. 325-340, 2002.

BAPTISTA, E. M. B. **Análise do perfil das empresas brasileiras segundo o nível de gerenciamento de resultados**. 2008. Tese (Doutorado em Administração) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2008.

BARBER, B. M.; GRIFFIN, P. A.; LEV, B. Fraud-on-the-Market Theory and the Indicators of Common Stocks' Efficiency, **The Journal of Corporation Law**, v. 19, p. 285, 1993.

BARTON, Jan. Does the use of financial derivatives affect earnings management decisions? **The Accounting Review**, v. 76, n. 1, p. 1-26, jan. 2001.

BEASLEY, Mark S. An empirical analysis of the relation between the board of director composition and financial statement fraud. **The Accounting Review**, v. 71, n. 4, p. 443-465, 1996.

BENEISH, Messod D. Detecting GAAP violation: implications for assessing earnings management among firms with extreme financial performance. **Journal of Accounting and Public Policy**, v. 16, p. 271-309, 1997.

BENEISH, Messod D. Incentives and penalties related to earnings overstatement that violate GAAP. **The Accounting Review**, v. 72, n. 4, p. 425-457, oct. 1999a.

BENEISH, Messod D. The detection of earnings manipulation. **Financial Analysts Journal**, v. 55, n. 5, p. 24-36, 1999b.

BERENSON, M. L.; LEVINE, D. M. **Basic Business Statistics**. 6. ed. Upper Saddle River: Prentice Hall, 1996.

BRASIL. Decreto-Lei n. 2.848, de 7 de dezembro de 1940. Código penal. **Diário Oficial [da República Federativa do Brasil]**, Rio de Janeiro, 31 de dezembro de 1940.

BRASIL. Lei n. 6.385, de 7 de dezembro de 1976. Dispõe sobre o mercado de valores mobiliários e cria a Comissão de Valores Mobiliários. **Diário Oficial [da República Federativa do Brasil]**, Brasília, 9 de dezembro de 1976.

BRASIL. Lei n. 6.404, de 15 de dezembro de 1976. Dispõe sobre as sociedades por ações. **Diário Oficial [da República Federativa do Brasil]**, Brasília, 17 de dezembro de 1976.

BRASIL. Constituição (1988). **Constituição da República Federativa do Brasil**: promulgada em 5 de outubro de 1988.

BRASIL. Lei n. 11.638, de 28 de dezembro de 2007. Altera e revoga dispositivos da Lei n. 6.404, de 15 de dezembro de 1976, e da Lei n. 6.385, de 7 de dezembro de 1976, e estende às sociedades de grande porte disposições relativas à elaboração e divulgação de demonstrações

financeiras. **Diário Oficial [da República Federativa do Brasil]**, Brasília, 28 de dezembro de 2007.

BRAZEL, J.; HALL, N.; JONES, K.; ZIMBELMAN, M. What Can Nonfinancial Performance Measures Tell Us About the Likelihood of Fraud? In: American Accounting Association Auditing Section 2006 Midyear Conference, Los Angeles, CA. **Anais...**, 2005.

CAUDILL, Steven B.; MIXON JR., Franklin G. Analysing misleading discrete responses: a *logit* model based on misclassified data. **Oxford Bulletin of Economics and Statistics**, v. 67, n. 1, p. 105-113, 2005.

CHEN, G.; FIRTH, M.; GAO, D. N.; RUI, O. M. Ownership structure, corporate governance, and fraud: Evidence from China. **Journal of Corporate Finance**, v. 12, n. 3, p. 424-448, 2006.

CHOO, Freddie; TAN, Kim. An “American dream” theory of corporate executive fraud. **Accounting Forum**, v. 31, p. 203-215, 2007.

CRUTCHLEY, Claire E.; JENSEN, Marlin R. H.; MARSHALL, Beverly B. Climate for scandal: corporate environments that contribute to accounting fraud. **The Financial Review**, v. 42, p. 53-73, 2007.

CUPERTINO, C. M. MARTINEZ, A. L. Qualidade da auditoria e earnings management: risk assessment através do nível dos accruals discricionários. **Contabilidade Vista & Revista**, v. 19, n. 3, 2008.

DAVIDSON, Russell; MacKINNON, James G. **Econometric theory and methods**. New York: Oxford, 2004.

DECHOW, Patricia M.; SLOAN, Richard G.; SWEENEY, Amy P. Detecting earnings management. **The Accounting Review**, v. 70, n. 2, p. 193-225, apr. 1995.

\_\_\_\_\_; RICHARDSON, Scott. A.; TUNA, İrem. Why are earnings kinky? An examination of the earnings management explanation. **Review of Accounting Studies**, v. 8, n. 2-3, p. 355-384, june 2003.

DESHMUKH, A.; TALLURU, T. A rule based fuzzy reasoning system for assessing the risk of management fraud. In: Systems, Man, and Cybernetics, 1997. 'Computational Cybernetics and Simulation', 1997 IEEE International Conference on. **Anais...** . v. 1, p. 669-673, 1997.

EISENHARDT, Kathleen M. Agency theory: an assessment and review. **The Academy of Management Review**, v. 14, n. 1, p. 57-74, jan. 1989.

ENGLE, R. F. Wald, likelihood ratio, and Lagrange multiplier tests in econometrics. In: ENGLE, R. F. **Handbook of Econometrics**. v. 2, p.775-826. Elsevier, 1984.

ERICKSON, Merle; HANLON, Michelle; MAYDEW, Edward L. How much will firms pay for earnings that do not exist? Evidence of taxes paid on allegedly fraudulent earnings. **The Accounting Review**, v. 79, n. 2, p. 387-408, 2004.

\_\_\_\_\_; \_\_\_\_\_. Is there a link between executive equity incentives and accounting fraud? **Journal of Accounting Research**, v. 44, n. 1, p. 113-143, mar. 2006.

ETTREDGE, Michael L.; SUN, Lili; LEE, Picheng; ANANDARAJAN, Asokan A. Is earnings fraud associated with high deferred tax and/or book minus tax levels? **Auditing: A Journal of Practice and Theory**, v. 27, n. 1, p. 1-33, 2008.

FANNING, K.; COGGER, K.; SRIVASTAVA, R. Detection of management fraud: a neural network approach. In: Artificial Intelligence for Applications, 1995. Proceedings., 11th Conference on. **Anais...** . p.220-223, 1995.

\_\_\_\_\_; \_\_\_\_\_. Neural network detection of management fraud using published financial data. **Intelligent Systems in Accounting, Finance & Management**, v. 7, n. 1, p. 21-41, 1998.

FEROZ, Ehsan H.; PARK, Kyungjoo; PASTENA, Victor S. The financial and market effects of the SEC's accounting and auditing enforcement releases. **Journal of Accounting Research**, v. 29, p. 107-142, 1991.

- FICH, E. M.; SHIVDASANI, A. Financial fraud, director reputation, and shareholder wealth. **Journal of Financial Economics**, v. 86, n. 2, p. 306–336, 2007.
- FREIDLIN, B.; GASTWIRTH, J. L. Should the Median Test be Retired from General Use? **The American Statistician**, v. 54, n. 3, p. 161-164, 2000.
- GAGANIS, Chrysovalantis. Classification techniques for the identification of falsified financial statements: a comparative analysis. **Intelligent Systems in Accounting, Finance and Management**, v. 16, p. 207-229, 2009.
- GASTWIRTH, J. I.; WANG, J. Nonparametric tests in small unbalanced samples: Application in employment-discrimination cases. **Canadian Journal of Statistics**, v. 15, n. 4, p. 339-348, 1987.
- GERETY, Mason; LEHN, Kenneth. The causes and consequences of accounting fraud. **Managerial and Decision Economics**, v. 18, p. 587-599, 1997.
- GOTTLIEB, O.; SALISBURY, C.; SHEK, H.; VAIDYANATHAN, V. Detecting Corporate Fraud: An Application of Machine Learning. **Working paper**, 2006.
- GREENE, W. H. **Econometric analysis**. 5 ed., 2003.
- GUJARATI, Damodar. **Econometria básica**. 4. ed. Rio de Janeiro: Elsevier, 2006.
- GUNTORPE, D. L. Business Ethics: A Quantitative Analysis of the Impact of Unethical Behavior by Publicly Traded Corporations. **Journal of Business Ethics**, v. 16, n. 5, p. 537-543, 1997.
- HART, A. Mann-Whitney test is not just a test of medians: differences in spread can be important. **BMJ**, v. 323, n. 7309, p. 391-393, 2001.

HAUSMAN, J. A. Specification tests in econometrics. **Econometrica**, v. 46, n. 6, p. 1251-1271, nov. 1978.

\_\_\_\_\_; ABREVAYA, J.; SCOTT-MORTON, F. M. Misclassification of the dependent variable in a discrete-response setting. **Journal of Econometrics**, v. 87, p. 239-269, 1998.

\_\_\_\_\_. Mismeasured variables in econometric analysis: Problems from the right and problems from the left. **Journal of Economic Perspectives**, p. 57-67, 2001.

HEALY, Paul M.; WAHLEN, James M. A review of the earnings management literature and its implications for standard setting. **American Accounting Association**, v. 13, n. 4, p. 365-383, 1999.

HINKLEY, David V. Jackknifing in unbalanced situations. **Technometrics**, v. 19, n. 3, ago. 1977.

HORN, Susan D.; HORN, Roger A.; DUNCAN, David B. Estimating heteroskedastic variances in linear models. **Journal of the American Statistical Association**, v. 70, n. 350, p. 380-385, jun. 1975.

HRIBAR, P.; COLLINS, D. Errors in estimating accruals: implications for empirical research. **Journal of Accounting Research**, V. 40, p. 105-134, 2002.

JENSEN, Michael C.; MECKLING, William H. Theory of the firm: managerial behavior, agency costs and ownership structure. **Journal of Financial Economics**, v. 3, n. 4, p. 305-360, oct. 1976.

JENSEN, Paul H.; PALANGKARAYA, Alfons; WEBSTER, Elizabeth. Misclassification in patent offices. **Working paper**, 2008.

JOHNSON, S. A.; RYAN, H. E.; TIAN, Y. S. Executive compensation and corporate fraud. **Economics Working Paper**, Louisiana State University, April, 2003.

JONES, Jennifer J. Earnings management during import relief investigations. **Journal of Accounting Research**, v. 29, n. 2, p. 193-228, 1991.

KAMINSKI, K. A.; WETZEL, T. S.; GUAN, L. Can financial ratios detect fraudulent financial reporting? **Managerial Auditing Journal**, v. 19, p. 15-28, 2004.

KIRKOS, E.; SPATHIS, C.; MANOLOPOULOS, Y. Data Mining techniques for the detection of fraudulent financial statements. **Expert Systems with Applications**, v. 32, n. 4, p. 995-1003, 2007.

KWASITSU, D. L. **Financial statement misrepresentation: could investors detect it?** 2004. 84p. Master of Science in Management – University of Lethbridge, Calgary.

LEE, Thomas A.; INGRAM, Robert W.; HOWARD, Thomas P. The difference between earnings and operating cash flow as an indicator of financial reporting fraud. **Contemporary Accounting Research**, v. 16, n. 4, p. 749-786, 1999.

LEVITT, Arthur. **Quality information: the lifeblood of our markets.** The Economic Club of New York, 18.10.1999. Disponível em: <<http://www.sec.gov/news/spchindx.htm>>

LIN, J. W.; HWANG, M. I.; BECKER, J. D. A fuzzy neural network for assessing the risk of fraudulent financial reporting. **Managerial Auditing Journal**, v. 657, p. 665, 2003.

MACKINNON, James G.; WHITE, Halbert. Some heteroskedasticity-consistent covariance matrix estimators with improved finite sample properties. **Journal of Econometrics**, v. 29, p. 305-325, 1985.

MANN, H. B.; WHITNEY, D. R. On a Test of Whether one of Two Random Variables is Stochastically Larger than the Other. **The Annals of Mathematical Statistics**, v. 18, n. 1, p. 50-60, 1947.

MARTINEZ, A. L. **"Gerenciamento" dos resultados contábeis: estudo empírico das companhias abertas brasileiras.** 2001. Tese (Doutorado em Ciências Contábeis) - Universidade de São Paulo, São Paulo, 2001.

MILLER, Gregory S. The press as a watchdog for accounting fraud. **Journal of Accounting Research**, v. 44, n. 5, p. 1001-1033, dec. 2006.

MURCIA, F. D.; BORBA, J. A.; AMARAL, N. Financial Report Restatements: Evidences from the Brazilian Financial Market. **SSRN eLibrary**, 2005.

\_\_\_\_\_; BORBA, J. A. Um estudo das fraudes contábeis sob suas óticas: jornais econômicos versus periódicos acadêmicos no período de 2001-2004. **Revista de Contabilidade do Mestrado em Ciências Contábeis da UERJ**, v. 10, p. 99-114, 2005.

\_\_\_\_\_; BORBA, J. A. Estrutura para detecção do risco de fraude nas demonstrações contábeis: mapeando o ambiente fraudulento. **Brazilian Business Review**, v. 4, n. 3, p. 171-190, 2007.

\_\_\_\_\_. **Relevância dos Red Flags na detecção do risco de fraudes nas demonstrações contábeis: a percepção de auditores independentes brasileiros**. 2007. Dissertação (Mestrado em Contabilidade). Universidade Federal de Santa Catarina, Florianópolis, 2007.

NEUHAUS, John M. Bias and efficiency loss due to misclassified responses in binary regression. **Biometrika**, v. 86, p. 843-855, 1999.

OGUT, Hulisi; AKTAS, Ramazan; ALP, Ali; DOGANAY, M. M. Prediction of financial information manipulation by using support vector machines and probabilistic neural network. **Expert Systems with Applications**, v. 36, p. 5419-5423, 2009.

PALMROSE, Zoe-Vonna; RICHARDSON, Vernon J.; SCHOLZ, Susan. Determinants of market reactions to restatement announcements. **Journal of Accounting and Economics**, v. 37, p. 59-89, 2004.

POIRIER, D. J. Partial observability in bivariate probit models. **Journal of Econometrics**, v. 12, n. 2, p. 209-217, 1980.

SCHNEEWEISS, Hans; AUGUSTIN, Thomas. Some recent advances in measurement error models and methods. **Allgemeines Statistisches Archiv**, v. 90, p. 183-197, 2006.

SHARMA, V. D. Board of Director Characteristics, Institutional Ownership, and Fraud: Evidence from Australia. **Auditing: A Journal of Practice & Theory**, v. 23, n. 2, p. 105-117, 2004.

SKOUSEN, Christopher J.; WRIGHT, Charlotte J. Contemporaneous risk factors and the prediction of financial statement fraud. **Journal of Forensic Accounting**, v. 9, p. 37-62, 2006.

SPATHIS C.T. Detecting false financial statements using published data: some evidence from Greece. **Managerial Auditing Journal**, v. 17, p. 179-191, 2002.

SPATHIS, Ch.; DOUMPOS, M.; ZOPOUNIDIS, C. Detecting falsified financial statements: a comparative study using multicriteria analysis and multivariate statistical techniques. **The European Accounting Review**, v. 11, n. 3, p. 509-535, 2002.

SUMMERS, Scott L.; SWEENEY, John T. Fraudulently misstated financial statements and insider trading: an empirical analysis. **The Accounting Review**, v. 73, n. 1, p. 131-146, jan. 1998.

TROY, Carmelita Janene. **The devil made me do it: managerial and strategic factors leading to accounting fraud**, 2003. Tese (Doctor of Philosophy) – University of Maryland, College Park, 2003.

TURNER, J. L.; MOCK, T. J.; SRIVASTAVA, R. P. An analysis of the fraud triangle. **The University of Memphis Working Paper**, 2003.

WANG, T. Y. Investment, shareholder monitoring and the economics of corporate securities fraud. **Working Paper**, 2004.

\_\_\_\_\_. Real Investment and Corporate Securities Fraud. **SSRN eLibrary**, 2008.

WHITE, Halbert. A heteroskedasticity-consistent covariance matrix estimator and a direct test for heteroskedasticity. **Econometrica**, v. 48, n. 4, p. 817-838, may 1980.



## APÊNDICE A – Experimento de Monte Carlo

Para verificar a possível magnitude desses vieses em problemas de fraude contábil, foi realizado um experimento de Monte Carlo. O modelo utilizado é o mesmo de Hausman et al. (1998):

$$y_i^* = -1 + 0,2x_{i1} + 1,5x_{i2} - 0,6x_{i3} + \varepsilon_i \quad (2.53)$$

Nessas simulações, a variável  $x_1$  é extraída de uma distribuição lognormal;  $x_2$  é uma variável *dummy* que assume o valor 1 com probabilidade 1/3; e  $x_3$  distribuída uniformemente. O termo de erro segue a distribuição normal. Considerou-se  $n = 5.000$ , e foram efetuadas 200 repetições para cada valor de  $\alpha_1$ .

Hausman (1998) considera  $\tilde{y}_i$  igual a 1 sempre que  $y_i^* > 0$ . Para diminuir o número de observações classificadas como possuindo a característica de interesse (de forma a utilizar um conjunto de dados mais próximo daqueles disponíveis para o estudo da fraude), considerou-se  $\tilde{y}_i$  é igual a 1 sempre que  $\Pr(y^* > y_i^*)$  é menor do que 5%. Desta forma, apenas um pequeno número de observações (5%) são marcadas como possuindo a característica de interesse, descrita pela variável dependente. Esse valor foi escolhido por ser baixo, mas bastante superior ao percentual de empresas com contabilidade fraudulenta observado por Beneish (1999) - que foi de 0,69% e por este estudo (0,42% - vide capítulo referente à metodologia).

Nessas simulações, os valores  $\alpha_1$  variam de 0% a 99%, em intervalos de 1%. Foram portanto realizadas 100 simulações, sendo que três modelos foram estimados em cada repetição: o modelo *probit* com a variável  $y$  real, outro com a variável  $\tilde{y}$ , e um modelo *probit* com erros de classificação utilizando a variável  $\tilde{y}$ . Os coeficientes estimados por esses modelos são respectivamente denotados por  $\hat{\beta}_k^r$ ,  $\hat{\beta}_k^o$  e  $\hat{\beta}_k^e$ .

Para simplificar a análise, os valores de  $\alpha_1$  foram divididos em 10 decis. O primeiro decil (1) contém os valores mais baixos de  $\alpha_1$ ; o último decil (10) contém os valores de  $\alpha_1$  entre 90% e 99%.

A condição para o uso dos valores estimados de  $\alpha_1$  e dos demais parâmetros da especificação com erro de classificação é a convergência do modelo. Ou seja, na eventualidade de um conjunto de dados não convergir antes de 100 iterações, ele era retirado do experimento. Os valores obtidos para os três modelos são mostrados na Tabela 21.

**Tabela 21: coeficientes estimados através dos três modelos**

A primeira coluna mostra os coeficientes estimados através de um modelo *probit* que utiliza os valores reais de  $y$  – especificação correta, portanto. A segunda coluna mostra os coeficientes estimados através de um modelo idêntico, porém com o  $y$  observado. Os coeficientes da terceira coluna foram obtidos utilizando-se o modelo *probit* com erros de classificação proposto por Hausman (1998). A medida de tendência central adotada é a mediana (primeira linha). A segunda linha mostra o desvio-padrão dos valores estimados, entre parênteses.

Decil de $\alpha_1$	Variável dependente		
	$\tilde{y}$	$y$	<i>Probit</i> corrigido
Painel 1: valores estimados para o coeficiente $\beta_1$			
1	0.2007 (0,0096)	0.1919 (0,0138)	0.1968 (0,0256)
2	0.2004 (0,0096)	0.1746 (0,0151)	0.2008 (0,0179)
3	0.1998 (0,0096)	0.1591 (0,0157)	0.1999 (0,0202)
4	0.2002 (0,0100)	0.1455 (0,0161)	0.2002 (0,0197)
5	0.2006 (0,0096)	0.1329 (0,0159)	0.2026 (0,0227)
6	0.2006 (0,0094)	0.1209 (0,0156)	0.2012 (0,0262)
7	0.1998 (0,0094)	0.1091 (0,0157)	0.2011 (0,0308)
8	0.2000 (0,0099)	0.0970 (0,0155)	0.2017 (0,0401)
9	0.2007 (0,0097)	0.0849 (0,0164)	0.2054 (0,0810)
10	0.1998 (0,0095)	0.0672 (0,0194)	0.2168 (1100,459)
Total	0.2003 (0,0096)	0.1265 (0,0406)	0.2010 331,0364

**Tabela 21: coeficientes estimados através dos três modelos - continuação**

Decil de $\alpha_1$	Variável dependente		
	$\tilde{y}$	$y$	<i>Probit corrigido</i>
Painel 2: valores estimados para o coeficiente $\beta_2$			
1	1.5015 (0,0669)	1.4715 (0,0725)	1.4792 (0,1394)
2	1.5050 (0,0693)	1.4168 (0,0737)	1.5049 (0,1017)
3	1.5020 (0,0661)	1.3595 (0,0725)	1.5027 (0,1094)
4	1.5011 (0,0664)	1.3058 (0,0770)	1.5023 (0,1099)
5	1.5043 (0,0683)	1.2540 (0,0809)	1.5104 (0,1301)
6	1.5044 (0,0680)	1.2030 (0,0856)	1.5180 (0,1456)
7	1.5012 (0,0672)	1.1408 (0,0898)	1.5152 (0,1682)
8	1.5020 (0,0669)	1.0812 (0,1015)	1.5185 (0,2155)
9	1.5032 (0,0668)	1.0047 (0,1225)	1.5428 (0,4918)
10	1.5014 (0,0677)	0.8788 (0,2930)	1.5932 7206,21
Total	1.5026 (0,0674)	1.2372 (0,2163)	1.5085 (2168,893)

**Tabela 21: coeficientes estimados através dos três modelos - continuação**

Decil de $\alpha_1$	Variável dependente		
	$\tilde{y}$	$y$	<i>Probit</i> corrigido
Painel 3: valores estimados para o coeficiente $\beta_3$			
1	-0.6013 (0,0905)	-0.5894 (0,0914)	-0.5857 (0,1075)
2	-0.6037 (0,0923)	-0.5656 (0,0956)	-0.6043 (0,1061)
3	-0.6014 (0,0892)	-0.5389 (0,0966)	-0.6021 (0,1128)
4	-0.6029 (0,0903)	-0.5215 (0,1014)	-0.6029 (0,1213)
5	-0.6033 (0,0924)	-0.4979 (0,1078)	-0.6104 (0,1377)
6	-0.6006 (0,0914)	-0.4680 (0,1131)	-0.6019 (0,1514)
7	-0.6021 (0,0902)	-0.4440 (0,1209)	-0.6057 (0,1746)
8	-0.6041 (0,0892)	-0.4171 (0,1356)	-0.6116 (0,2100)
9	-0.6052 (0,0920)	-0.3947 (0,1652)	-0.6329 (0,3081)
10	-0.6021 (0,0900)	-0.3397 (0,4811)	-0.6255 (8323,372)
Total	-0.6026 (0,0908)	-0.4936 (0,1938)	-0.6042 (2496,689)

**Tabela 21: coeficientes estimados através dos três modelos - continuação**

Decil de $\alpha_1$	Variável dependente		
	$\tilde{y}$	$y$	<i>Probit</i> corrigido
Painel 4: valores estimados para a constante			
1	-2.6893 (0,0778)	-2.6777 (0,0828)	-2.7022 (0,1422)
2	-2.6925 (0,0820)	-2.6707 (0,0875)	-2.6968 (0,0980)
3	-2.6859 (0,0783)	-2.6730 (0,0859)	-2.6920 (0,1133)
4	-2.6853 (0,0781)	-2.6873 (0,0911)	-2.6925 (0,1080)
5	-2.6897 (0,0800)	-2.7139 (0,0929)	-2.6971 (0,1216)
6	-2.6916 (0,0789)	-2.7621 (0,0974)	-2.7040 (0,1364)
7	-2.6866 (0,0802)	-2.8153 (0,1040)	-2.7055 (0,1559)
8	-2.6844 (0,0781)	-2.8980 (0,1149)	-2.7207 (0,1925)
9	-2.6875 (0,0782)	-3.0302 (0,1420)	-2.7431 (0,4519)
10	-2.6869 (0,0812)	-3.2920 (0,2373)	-2.8813 (8596.255)
Total	-2.6876 (0,0793)	-2.7619 (0,2279)	-2.7068 (2585.602)

Pode-se perceber que o valor dos coeficientes estimados pelo modelo *probit* simples com erros de classificação tornam-se cada vez mais viesados à medida que o erro aumenta. O coeficiente estimado através do modelo *probit* com erros de classificação também se afasta um pouco do valor esperado quando o erro aumenta.

Para verificar se esse viés é significativo, foi feito o teste do sinal para cada um dos coeficientes (apenas para o 10º decil) com as seguintes hipóteses:

$$H_0: \hat{\beta}_k^e - \hat{\beta}_k^r = 0$$

$$H_1: \hat{\beta}_k^e - \hat{\beta}_k^r \neq 0$$

Também deseja-se verificar se as estimativas de  $\alpha_1$  obtidas através do modelo com erros de classificação são confiáveis. Para tanto, utiliza-se o teste do sinal com as seguintes hipóteses:

$$H_0: \hat{\alpha}_1 - \alpha_1 = 0$$

$$H_1: \hat{\alpha}_1 - \alpha_1 \neq 0$$

Os resultados, apresentados na Tabela 22, confirmam que, mesmo com a correção proposta por Hausman (1998), ainda pode ocorrer um viés (atenuado) no vetor  $\beta$ , especialmente quando os erros são grandes. A estimativa do coeficiente  $\alpha_1$ , por outro lado, é consistente.

**Tabela 22: teste do sinal sobre o viés dos coeficientes (apenas último decil)**

	Sinais		P-valor bicaudal
	Positivos	Negativos	
$\hat{\beta}_1^e - \hat{\beta}_1^r$	1022	746	0.0000
$\hat{\beta}_2^e - \hat{\beta}_2^r$	1016	752	0.0000
$\hat{\beta}_3^e - \hat{\beta}_3^r$	841	927	0.0432
$\hat{\beta}_0^e - \hat{\beta}_0^r$	596	1172	0.0000
$\hat{\alpha}_1^e - \alpha_1$	888	880	0.8678

## APÊNDICE B – Notação Matemática

Em alguns tópicos deste trabalho, é inevitável o uso de expressões matemáticas. Com o objetivo de facilitar a compreensão, este apêndice reúne e explica rapidamente algumas notações adotadas.

a) variáveis, vetores e matrizes: uma letra minúscula em itálico denota uma variável. Por exemplo,  $y_i$  refere-se ao valor assumido pela variável dependente  $y$  na  $i$ -ésima observação. Letras minúsculas em negrito representam vetores (colunas). Portanto,  $\mathbf{y}$  é um vetor coluna com os valores assumidos pela variável  $y$  para cada uma das observações. Uma letra maiúscula em negrito é uma matriz. Assim,  $\mathbf{X}$  é uma matriz em que cada coluna representa uma das variáveis da matriz, e cada linha é uma observação.

b) derivadas: adota-se a notação de Leibniz ( $dy/dx$ ). Formalmente, no caso de uma função  $y = f(x)$ :

$$\frac{dy}{dx} = \lim_{\Delta x \rightarrow 0} \frac{\Delta y}{\Delta x}$$

Se a função tiver mais de uma variável independente - por exemplo,  $z = f(x, y)$ , pode-se escrever a derivada parcial como  $\partial z / \partial x$ . Derivadas parciais de segunda ordem são expressas como, por exemplo,  $\partial^2 z / \partial x \partial y$  ou  $\partial^2 z / \partial x^2$ .

c) probabilidades: As probabilidades são abreviadas como Prob. Assim,  $\text{Prob}(y = 1 | \mathbf{x})$  significa “probabilidade da variável  $y$  ser igual a 1, condicionada ao vetor  $\mathbf{x}$ ”.

d) funções de probabilidades: como de costume, a função normal é simbolizada por  $\phi$ . A função normal cumulativa é  $\Phi$ . A função logística é representada por  $\Lambda$ .