

**UNIVERSIDADE CATÓLICA
PORTUGUESA . PORTO**
FACULDADE DE ECONOMIA E GESTÃO

MESTRADO EM FINANÇAS

Tese submetida à Faculdade de Economia e Gestão da Universidade Católica Portuguesa, Centro Regional do Porto, em cumprimento parcial dos requisitos para a obtenção do grau de Mestre em Finanças.

Modalidade de Trabalho

Dissertação

Tema

A importância dos dados setoriais na previsão financeira. Aplicação ao ROA

Nome Aluno

Francisco José Mairós de Sousa Falcão dos Reis

Data

Novembro/2011

“Há um tempo em que é preciso abandonar as roupas usadas, que já têm a forma do nosso corpo, e esquecer os nossos caminhos, que nos levam sempre aos mesmos lugares. É o tempo da travessia: e, se não ousarmos fazê-la, teremos ficado, para sempre, à margem de nós mesmos.”

Fernando Pessoa

Agradecimentos

Viver é partilhar. Partilham-se sonhos e responsabilidades, conquistas e derrotas. Assim, este Trabalho não é reflexo apenas do esforço e dedicação do seu autor, mas também de todo o seu meio envolvente. Desta forma e sem nenhuma ordem especial, gostaria de deixar os meus sinceros agradecimentos às pessoas que me ajudaram a concluir mais um objetivo pessoal.

Ao Prof. Dr. Luís Pacheco pela sua frontalidade, orientação e imensa disponibilidade.

Aos meus pais, tios e avós, porque sem eles, seguramente, não seria hoje quem sou.

Aos meus amigos, pela profundidade de todas as conversas que me ajudaram a esclarecer todas as dúvidas exceto as relacionadas com este Trabalho.

Para a minha mulher, pilar da minha existência, dedico este Trabalho e todos os segundos da minha vida. *“Through the good or lean years and for all the in between years, come what may.”*

Abstract

In this work we investigate the importance of the use of sector data in the financial forecasting of the indicator Return on Assets (ROA) for a sample of 291 firms in the footwear manufacturing sector in Portugal.

To measure the impact of sector data in the forecasting process we use five historical data sets: i) of the company, ii) of the sector, iii) combination between company and sector data and iv) of the subsector, to obtain forecasts from a simple forecasting method: the percentage-of-sales. We used this method in order to obtain an approximation to the forecasting methods used in Small and Medium Enterprises (SME) (Armstrong, 2009; Dalrymple, 1987) which represented more than 99,7% of the Portuguese business sector in 2008 (INE, 2010).

Our results suggest that the use of sector data can improve the accuracy of ROA forecasts, in particular through the combination of sector and company historical data.

The use of sector data, relative to the use of company data, obtained more accurate forecasts for Sales and Assets Turnover and less accurate forecasts for the Gross Margin Rate, Cost Control Effect and Operating Return on Sales. These results suggest that both Sales and Adjusted Assets values converge to the sector while the Gross Margin, Operational Result and the difference between them don't converge.

Sorting the sample by firm size, using the Adjusted Assets value as a criterion, the obtained results suggest that as firm size diminishes the predictive ability of sector data increases.

This work fills a gap in the Corporate Finance literature, particularly in the Financial Forecast subject, with respect to the use of sector data in order to increase forecasting accuracy.

Keywords: Financial Forecasting, sector data, ROA.

Sumário Executivo

Neste Trabalho investigamos qual a importância da utilização de dados setoriais na previsão financeira do indicador Retorno Operacional do Ativo (ROA) para uma amostra de 291 empresas do setor do fabrico de calçado em Portugal.

Para medição do impacto dos dados setoriais na previsão utilizamos cinco conjuntos de dados históricos: i) da empresa, ii) do setor, iii) combinação de dados da empresa e do setor e iv) subsetoriais, para obter as previsões com recurso a um método de previsão simples: percentagem das vendas. Utilizamos este método de forma a permitir uma aproximação aos métodos de previsão utilizados pelas Pequenas e Médias Empresas (PME) (Armstrong, 2009; Dalrymple, 1987) que representam cerca de 99,7% do tecido empresarial português em 2008 (INE, 2010).

Os resultados obtidos sugerem que a utilização de dados setoriais pode aumentar a precisão das previsões do ROA, nomeadamente via combinação deste tipo de dados com os históricos da própria empresa.

A utilização de dados setoriais obteve previsões mais precisas para o Volume de Negócios e para o Grau de Rotação do Ativo do que os dados da empresa e obteve previsões menos precisas para os indicadores Taxa de Margem Bruta, Efeito de Controlo de Custos e Rentabilidade Operacional do Ativo. Estes resultados sugerem que o Volume de Negócios e o Ativo Corrigido convergem para os valores setoriais, enquanto a Margem Bruta, Resultado Operacional e a diferença entre ambos não convergem.

Com a ordenação da amostra por dimensão da empresa, utilizando como critério o valor da conta Ativo Corrigido, os resultados de previsão obtidos sugerem que à medida que a dimensão da empresa vai diminuindo a capacidade preditiva dos dados setoriais aumenta.

Este Trabalho vem preencher uma lacuna existente na literatura das Finanças Empresariais, nomeadamente na temática de Previsão Financeira, no que diz respeito à utilização de dados setoriais no aumento da precisão das previsões.

Palavras-chave: Previsão Financeira, dados setoriais, ROA.

Índice

AGRADECIMENTOS	II
ABSTRACT	III
SUMÁRIO EXECUTIVO	IV
ÍNDICE	V
ÍNDICE DE TABELAS	VI
LISTA DE FIGURAS	VIII
1. INTRODUÇÃO	I
2. A PREVISÃO FINANCEIRA NA GESTÃO EMPRESARIAL	4
2.1. PREVISÃO FINANCEIRA E ORÇAMENTAÇÃO.....	4
2.2. IMPORTÂNCIA DA PREVISÃO FINANCEIRA NA GESTÃO EMPRESARIAL.....	6
2.2.1. <i>Qualidade e precisão das previsões financeiras</i>	8
2.2.2. <i>Impacto interno e externo da previsão financeira</i>	12
2.3. MÉTODOS DE PREVISÃO FINANCEIRA.....	14
3. MODELOS DE PREVISÃO FINANCEIRA	18
3.1. MODELIZAÇÃO FINANCEIRA.....	18
3.2. CONSTRUÇÃO DE MODELOS FINANCEIROS.....	20
3.3. UTILIZAÇÃO DE MODELOS FINANCEIROS.....	22
4. DESENVOLVIMENTO DO MODELO	24
4.1. OBJETIVO DO ESTUDO E DESENVOLVIMENTO DAS HIPÓTESES.....	24
4.2. ESCOLHA E DESENVOLVIMENTO DO MODELO DE PREVISÃO FINANCEIRA.....	26
5. ANÁLISE DE RESULTADOS	30
5.1. MEDIDAS DE AVALIAÇÃO DE PRECISÃO DAS PREVISÕES.....	31
5.2. RESULTADOS GLOBAIS.....	33
5.2.1. <i>Conjunto de dados da empresa e do setor</i>	33
5.2.2. <i>Conjunto de dados combinados</i>	37
5.3. RESULTADOS POR QUINTIS.....	44
5.4. RESULTADOS DA PREVISÃO FINANCEIRA COM RECURSO A DADOS SUBSETORIAIS.....	56
6. CONCLUSÃO	70
6.1. CONCLUSÕES.....	70
6.2. CONTRIBUTOS.....	73
6.3. LIMITAÇÕES E SUGESTÕES PARA INVESTIGAÇÃO FUTURA.....	74
BIBLIOGRAFIA	75

Total de Palavras: 23.578

Índice de Tabelas

Capítulo 4.2

TABELA 4.2-1: DEMONSTRAÇÃO DE RESULTADOS	27
--	----

Capítulo 5.1

TABELA 5.1-1: FÓRMULAS DAS MEDIDAS DE PRECISÃO DE PREVISÃO	31
--	----

Capítulo 5.2

TABELA 5.2-1: MEDIDAS DE PRECISÃO DAS PREVISÕES DO ROA PARA O TOTAL DA AMOSTRA (E E S).....	33
TABELA 5.2-2: NÚMERO DE EMPRESAS COM PREVISÃO DO ROA MAIS PRECISA POR CONJUNTO DE DADOS (E E S).....	34
TABELA 5.2-3: MEDIDAS DE PRECISÃO DAS PREVISÕES DO VN PARA O TOTAL DA AMOSTRA (E E S).....	35
TABELA 5.2-4: NÚMERO DE EMPRESAS COM PREVISÃO DO VN MAIS PRECISA POR CONJUNTO DE DADOS (E E S).....	35
TABELA 5.2-5: MEDIDAS DE PRECISÃO DAS PREVISÕES DOS INDICADORES TMB, ECC, ROVN E GRA PARA O TOTAL DA AMOSTRA	35
TABELA 5.2-6: ANÁLISE DE SENSIBILIDADE DOS QUATRO INDICADORES	36
TABELA 5.2-7: NÚMERO DE EMPRESAS COM PREVISÃO DO ROA MAIS PRECISA POR CONJUNTO DE DADOS (E E C1).....	37
TABELA 5.2-8: MEDIDAS DE PRECISÃO DAS PREVISÕES DO ROA PARA O TOTAL DA AMOSTRA (E E C1)	37
TABELA 5.2-9: COMPARAÇÃO DAS MEDIDAS DE PRECISÃO DAS PREVISÕES DO ROA COM RECURSO AOS CONJUNTOS DE DADOS E, S E C1	38
TABELA 5.2-10: MEDIDAS DE PRECISÃO DAS PREVISÕES DO GRA PARA O TOTAL DA AMOSTRA (E E C1)	39
TABELA 5.2-11: NÚMERO DE EMPRESAS COM PREVISÃO DO ROA MAIS PRECISA POR CONJUNTO DE DADOS (E E C2)	39
TABELA 5.2-12: MEDIDAS DE PRECISÃO DAS PREVISÕES DO ROA PARA O TOTAL DA AMOSTRA (E E C2).....	39
TABELA 5.2-13: COMPARAÇÃO DAS MEDIDAS DE PRECISÃO DAS PREVISÕES DO ROA COM RECURSO AOS CONJUNTOS DE DADOS E, S, C1 E C2	40
TABELA 5.2-14: NÚMERO DE EMPRESAS COM PREVISÃO DO VN MAIS PRECISA POR CONJUNTO DE DADOS (E E C2).....	41
TABELA 5.2-15: COMPARAÇÃO DAS MEDIDAS DE PRECISÃO DAS PREVISÕES DO VN COM RECURSO AOS CONJUNTOS DE DADOS E, S E C2	41
TABELA 5.2-16: NÚMERO DE EMPRESAS COM PREVISÃO DOS QUATRO INDICADORES MAIS PRECISA POR CONJUNTO DE DADOS (E E C2).....	42
TABELA 5.2-17: MEDIDAS DE PRECISÃO DAS PREVISÕES DOS QUATRO INDICADORES PARA O TOTAL DA AMOSTRA (E, S E C2).....	43

Capítulo 5.3

TABELA 5.3-1: NÚMERO DE EMPRESAS POR QUINTIL COM PREVISÕES DO ROA MAIS PRECISAS PARA CADA CONJUNTO DE DADOS....	44
TABELA 5.3-2: MEDIDAS DE PRECISÃO DAS PREVISÕES DO ROA PARA O PRIMEIRO QUINTIL.....	46
TABELA 5.3-3: MEDIDAS DE PRECISÃO DAS PREVISÕES DO VN PARA O PRIMEIRO QUINTIL.....	46
TABELA 5.3-4: MEDIDAS DE PRECISÃO DAS PREVISÕES DOS QUATRO INDICADORES PARA O PRIMEIRO QUINTIL.....	47
TABELA 5.3-5: MEDIDAS DE PRECISÃO DAS PREVISÕES DO ROA PARA O SEGUNDO QUINTIL	48
TABELA 5.3-6: MEDIDAS DE PRECISÃO DAS PREVISÕES DO VN PARA O SEGUNDO QUINTIL.....	49
TABELA 5.3-7: MEDIDAS DE PRECISÃO DAS PREVISÕES DOS QUATRO INDICADORES PARA O SEGUNDO QUINTIL	49
TABELA 5.3-8: MEDIDAS DE PRECISÃO DAS PREVISÕES DO ROA PARA O TERCEIRO QUINTIL.....	50

TABELA 5.3-9: MEDIDAS DE PRECISÃO DAS PREVISÕES DO VN PARA O TERCEIRO QUINTIL.....	51
TABELA 5.3-10: MEDIDAS DE PRECISÃO DAS PREVISÕES DOS QUATRO INDICADORES PARA O TERCEIRO QUINTIL.....	51
TABELA 5.3-11: MEDIDAS DE PRECISÃO DAS PREVISÕES DO ROA PARA O QUARTO QUINTIL.....	52
TABELA 5.3-12: MEDIDAS DE PRECISÃO DAS PREVISÕES DO VN PARA O QUARTO QUINTIL.....	53
TABELA 5.3-13: MEDIDAS DE PRECISÃO DAS PREVISÕES DOS QUATRO INDICADORES PARA O QUARTO QUINTIL.....	53
TABELA 5.3-14: MEDIDAS DE PRECISÃO DAS PREVISÕES DO ROA PARA O QUINTO QUINTIL.....	54
TABELA 5.3-15: MEDIDAS DE PRECISÃO DAS PREVISÕES DO VN PARA O QUINTO QUINTIL.....	54
TABELA 5.3-16: MEDIDAS DE PRECISÃO DAS PREVISÕES DOS QUATRO INDICADORES PARA O QUINTO QUINTIL.....	54

Capítulo 5.4

TABELA 5.4-1: MEDIDAS DE PRECISÃO DAS PREVISÕES DO ROA (E, S E SS).....	57
TABELA 5.4-2: NÚMERO DE EMPRESAS COM PREVISÃO DO ROA MAIS PRECISA POR CONJUNTO DADOS (E E SS).....	57
TABELA 5.4-3: NÚMERO DE EMPRESAS COM PREVISÃO DO VN MAIS PRECISA POR CONJUNTO DADOS (E E SS).....	58
TABELA 5.4-4: MEDIDAS DE PRECISÃO DAS PREVISÕES DO VN (E, S E SS).....	58
TABELA 5.4-5: MEDIDAS DE PRECISÃO DAS PREVISÕES DOS QUATRO INDICADORES (E, S E SS).....	59
TABELA 5.4-6: MEDIDAS DE PRECISÃO DAS PREVISÕES DO ROA PARA O PRIMEIRO SUBSETOR (E, S E SS).....	60
TABELA 5.4-7: MEDIDAS DE PRECISÃO DAS PREVISÕES DO VN PARA O PRIMEIRO SUBSETOR (E, S E SS).....	60
TABELA 5.4-8: MEDIDAS DE PRECISÃO DAS PREVISÕES DOS QUATRO INDICADORES PARA O PRIMEIRO SUBSETOR.....	61
TABELA 5.4-9: MEDIDAS DE PRECISÃO DAS PREVISÕES DO ROA PARA O SEGUNDO SUBSETOR (E, S E SS).....	62
TABELA 5.4-10: MEDIDAS DE PRECISÃO DAS PREVISÕES DO VN PARA O SEGUNDO SUBSETOR (E, S E SS).....	62
TABELA 5.4-11: MEDIDAS DE PRECISÃO DAS PREVISÕES DOS QUATRO INDICADORES PARA O SEGUNDO SUBSETOR (E, S E SS).....	63
TABELA 5.4-12: MEDIDAS DE PRECISÃO DAS PREVISÕES DO ROA PARA O TERCEIRO SUBSETOR (E, S E SS).....	64
TABELA 5.4-13: MEDIDAS DE PRECISÃO DAS PREVISÕES DO VN PARA O TERCEIRO SUBSETOR (E, S E SS).....	64
TABELA 5.4-14: MEDIDAS DE PRECISÃO DAS PREVISÕES DOS QUATRO INDICADORES PARA O TERCEIRO SUBSETOR (E, S E SS).....	65
TABELA 5.4-15: MEDIDAS DE PRECISÃO DAS PREVISÕES DO ROA PARA O QUARTO SUBSETOR (E, S E SS).....	66
TABELA 5.4-16: MEDIDAS DE PRECISÃO DAS PREVISÕES DO VN PARA O QUARTO SUBSETOR (E, S E SS).....	66
TABELA 5.4-17: MEDIDAS DE PRECISÃO DAS PREVISÕES DOS QUATRO INDICADORES PARA QUARTO SUBSETOR (E, S E SS).....	67
TABELA 5.4-18: MEDIDAS DE PRECISÃO DAS PREVISÕES DO ROA PARA QUINTO SUBSETOR (E, S E SS).....	68
TABELA 5.4-19: MEDIDAS DE PRECISÃO DAS PREVISÕES DO VN PARA QUINTO SUBSETOR (E, S E SS).....	68
TABELA 5.4-20: MEDIDAS DE PRECISÃO DAS PREVISÕES DOS QUATRO INDICADORES PARA O QUINTO SUBSETOR (E, S E SS).....	69

Capítulo 6.1

TABELA 6.1-1: NÚMERO DE EMPRESAS COM PREVISÃO DO ROA MAIS PRECISA PARA O TOTAL DA AMOSTRA POR CONJUNTO DE DADOS.....	71
--	----

Lista de Figuras

Capítulo 2.1

FIGURA 2.1-1: O PROCESSO DE PLANEAMENTO DA EMPRESA 6

Capítulo 2.2

FIGURA 2.2-1: ETAPAS CHAVE NO PROCESSO DE MONITORIZAÇÃO DA PREVISÃO FINANCEIRA 11

Capítulo 2.3

FIGURA 2.3-1: ÁRVORE DE SELEÇÃO PARA MÉTODOS DE PREVISÃO 15

Capítulo 3.2

FIGURA 3.2-1: DEMONSTRAÇÃO DE RESULTADOS PREVISIONAL..... 21

Capítulo 5.3

FIGURA 5.3-1: EVOLUÇÃO DO NÚMERO DE EMPRESAS QUE CADA CONJUNTO DE DADOS MELHOR PREVIU 45

I. Introdução

O processo de previsão financeira está intrinsecamente ligado à definição da estratégia empresarial (Armstrong, 1983; Makridakis, 1996). Um processo de previsão financeira eficientemente desenvolvido permite à empresa, entre outras situações, antecipar as suas necessidades de recursos, contribuir para a maximização da criação de valor para o acionista e otimizar a correta alocação interna de recursos (Fabozzi, 2003; Vadasz, 2005).

Usualmente, a previsão financeira é feita com recurso a modelos financeiros, contudo, os métodos de opinião são ainda frequentemente utilizados na gestão empresarial para, por exemplo, prever variáveis como o volume de negócios (Armstrong, 2009).

Hoje em dia, existem modelos financeiros baseados em redes neuronais e algoritmos de aprendizagem, cuja complexidade acrescida não parece ser acompanhada por ganhos significativos no aumento de precisão das previsões. Contudo, a criação de modelos financeiros complexos parece, ainda que somente para alguns, sinónimo de sofisticação e precisão elevada (Hogarth, 2006; Armstrong, 2009).

A eventual complexidade gerada na modelização financeira parece ser desnecessária pois pode tornar os modelos difíceis de perceber por parte de quem tem de tomar decisões com base nas projeções geradas. Esta dificuldade na interpretação, aliada aos elevados custos que estes modelos podem representar para a empresa, são indicadores de algumas das desvantagens do uso de elevada complexidade na modelização financeira.

Tipicamente, as empresas utilizam os seus dados históricos para efetuarem as suas previsões (Fabozzi, 2003). Posteriormente, as previsões são comparadas com as previsões de empresas congéneres e/ou com as previsões para o setor. Apesar dos dados setoriais serem considerados importantes, não foi encontrado na literatura nenhum estudo empírico publicado em revista de renome sobre os impactos da utilização de dados setoriais no processo de previsão financeira.

De facto, esta limitação da inexistência de estudos empíricos sobre este tema é por nós considerada como uma oportunidade para, com este Trabalho, ajudarmos a criar as bases

necessárias para o futuro desenvolvimento de estudos sobre a utilização de dados do setor na previsão financeira.

Desta forma, o principal objetivo deste Trabalho é o de perceber se a informação contida nos dados setoriais pode, de facto, aumentar a precisão das previsões financeiras e em que situações isso se pode verificar.

Para estudar esse impacto utilizamos um modelo financeiro baseado no método da percentagem das vendas para projetar as variáveis ligadas às vendas no futuro e utilizamos médias históricas de crescimento para projetar as restantes.

São analisados cinco conjuntos de dados:

- Históricos da empresa;
- Históricos do setor;
- Combinação de dados históricos da empresa e do setor:
 - Previsão apenas do volume de negócios com dados setoriais e restantes com dados da empresa (cenário base);
 - Combinação de dados históricos da empresa e do setor para todas as variáveis (teste de robustez);
- Históricos subsetoriais.

O modelo utilizado foi escolhido de forma a refletir melhor a previsão financeira de uma pequena empresa e por conseguinte conseguirmos uma aproximação à realidade nacional. O objetivo é contribuir para o aumento do conhecimento científico das empresas, nomeadamente as nacionais, de uma forma que elas possam compreender e utilizar.

Para concluir sobre a precisão das previsões utilizamos seis medidas de precisão amplamente utilizadas tanto no mundo académico como no profissional (Carbone-Armstrong, 1982) e constatamos que a inclusão de dados setoriais pode aumentar a precisão das previsões diminuindo a amplitude do erro e o peso do erro na observação. Os resultados obtidos sugerem que a capacidade preditiva dos dados setoriais e subsetoriais está inversamente relacionada com a dimensão da empresa e os dados da empresa e a combinação de dados (cenário base) apresentam uma relação positiva com a dimensão da empresa.

○ Trabalho está dividido em três partes fundamentais:

- A primeira parte engloba dois capítulos de revisão da literatura relacionada. O capítulo dois define e contextualiza a importância da previsão financeira. O capítulo três explora a criação e desenvolvimento de modelos financeiros.
- A segunda parte engloba, também, em dois capítulos. O capítulo quatro apresenta o objetivo do Trabalho, as hipóteses a serem testadas e a criação do modelo utilizado. O capítulo cinco refere-se à apresentação e discussão dos resultados obtidos.
- A terceira e última parte deste Trabalho encerra as principais conclusões obtidas ao longo do estudo.

2. A Previsão Financeira na gestão empresarial

2.1. Previsão Financeira e Orçamentação

Na atividade empresarial, a elaboração do orçamento e das previsões para o ano seguinte são uma das atividades mais importantes que a equipa de gestão pode fazer para garantir o sucesso do negócio (Cassar-Gibson, 2008). Também Shim e Siegel (2008a) reforçam esta ideia: “Financial forecasting, an essential element of planning, is the basis for budgeting activities. It is also needed when estimating future financing requirements.”

De acordo com o trabalho de Baker (1999), as empresas muitas vezes confundem previsão com planeamento, na medida em que usam a previsão como uma ferramenta para motivar os seus funcionários, ou seja, usam a previsão para influenciar o comportamento em vez de fazer a previsão condicionada pelo comportamento.

Então, o que é a previsão financeira e como se pode distinguir de outros processos inerentes ao planeamento? Entre outros autores, Vadasz (2005), Hyndman (2009) e Hosmand (2010) esclarecem-nos.

“To create a forecast is to articulate an objective and realistic assessment of the organization’s likely outturn on the basis of actual trends, current assumptions, and plans and budgets, in the absence of additional management interventions.” (Vadasz, 2005)

“Forecasting is about predicting the future as accurately as possible, given all the information available including historical data and knowledge of any future events that might impact the forecasts.” (Hyndman, 2009)

Financial forecasting allows the financial manager to anticipate events before they occur, particularly the need for raising funds externally. The most comprehensive means of financial forecasting is to develop a series of pro forma, or projected, financial statements. Based on the projected statements, the firm is able to estimate its future levels of receivables, inventory, payables, and other corporate accounts as well as its anticipated profits and borrowing requirements. (Hoshmand, 2010)

Como podemos constatar destas definições de previsão financeira, a previsão recorre a toda a informação disponível da empresa para definir, analisar e planear o futuro. Podemos dizer que o exercício proveniente da elaboração das previsões permite à equipa de gestão conhecer melhor a sua empresa e o mercado onde atua, para com base nesse

conhecimento definir as linhas orientadoras e estratégicas para o futuro do negócio. Daqui retiramos que o principal objetivo da previsão financeira é o de apoio à tomada de decisão.

Igualmente ligada à definição da estratégia está a orçamentação. Fabozzi e Peterson (2003), Harvard Business School (2005) e Shim e Siegel (2008a) clarificam-nos relativamente à sua definição.

When managers look at the firm's investment decisions and consider how to finance them, they are budgeting. Budgeting is mapping out the sources and uses of funds for future periods. Budgeting requires both economic analysis (including forecasting) and accounting. (Fabozzi-Peterson, 2003)

A budget "is the translation of strategic plans into measurable quantities that express the expected resources required and anticipated returns over a certain period. A budget thus can function as an action plan. It may also present an organization's estimated future financial statements. Finally, a budget is an adaptable tool for management to use to achieve its strategic goals." (Harvard Business School, 2005)

Budgets are blueprints for projected action and a formalization of the planning process. Plans are expressed in quantitative and monetary terms. Planning is taking an action based on investigation, analysis and research. [...] A sound budget process communicates organizational goals, allocates resources, provides feedback, and motivates employees. (Shim-Siegel, 2008a)

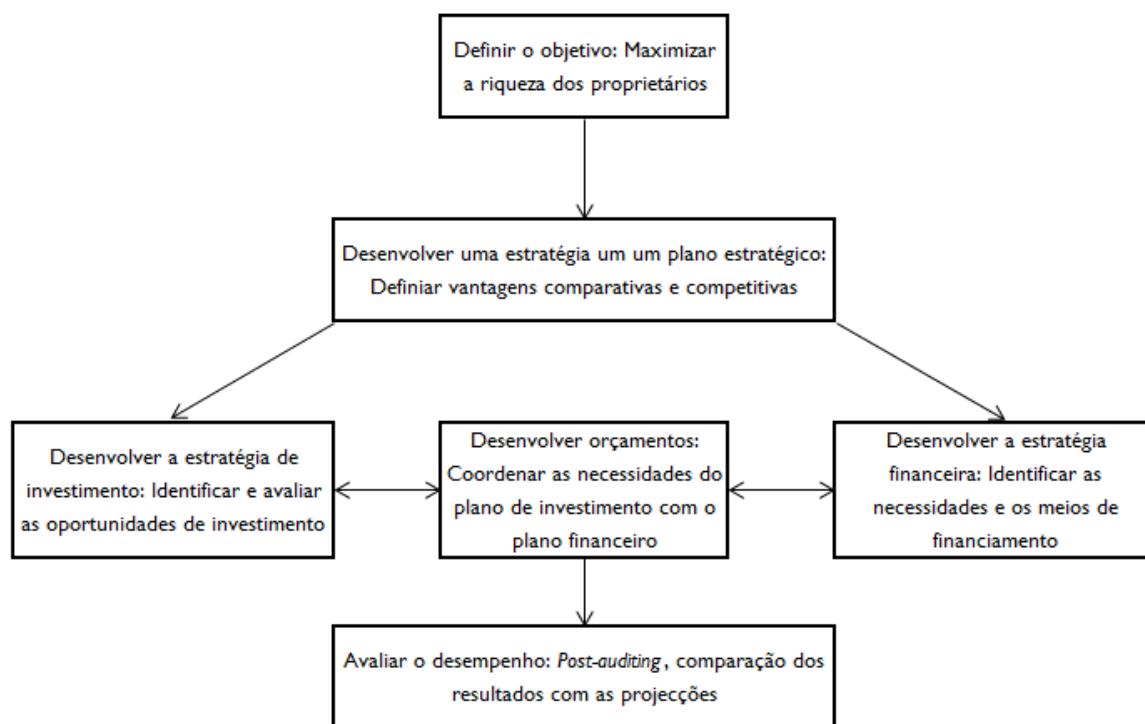
Como podemos concluir, a orçamentação significa quantificar as decisões estratégicas tomadas no sentido de alcançar os objetivos previamente definidos pela equipa de gestão. É precisamente este o principal objetivo da orçamentação: quantificar a estratégia empresarial.

Em suma, ambos os exercícios são fundamentais para uma gestão eficaz da empresa e ambos os exercícios estão interligados (Harvard Business School, 2005). Horngren et al. (1999) distingue, no caso da variável vendas, que uma previsão de vendas é uma predição dado um conjunto de circunstâncias, enquanto o orçamento para as vendas é o resultado de um conjunto de decisões para criarem as condições necessárias para se atingir um determinado valor de vendas desejado. Daqui se retira que o orçamento pressupõe a elaboração de um plano de ação para a empresa onde são claramente definidos os objetivos e os meios para os alcançar. Já a previsão é independente do objetivo definido. Dada a conjuntura externa, interna e assumido um determinado conjunto de pressupostos a previsão é o reflexo do modelo criado, ou seja, se o mundo criado pelo

modelo acontecesse na realidade, a previsão seria o que de facto aconteceria. Na Figura 2.2-1 está esquematizado o processo de planeamento de uma empresa, relacionando os dois conceitos, de acordo com Fabozzi-Peterson (2003).

Figura 2.1-1

O processo de planeamento da Empresa



Fonte: Adaptado de Fabozzi-Peterson (2003)

2.2. Importância da previsão financeira na Gestão Empresarial

In virtually every decision they make, executives today consider some kind of forecast. Sound predictions of demands and trends are no longer luxury items, but a necessity, if managers are to cope with seasonality, sudden changes in demand levels, price-cutting maneuvers of the competition, strikes, and large swings of the economy. Forecasting can help them deal with these troubles; but it can help them more, the more they know about the general principles of forecasting, what it can and cannot do for them currently, and which techniques are suited to their needs of the moment. (Chambers, et al., 1971)

Desta forma, a equipa de gestão interessa-se essencialmente na condução do negócio pelo que recorre às previsões financeiras e ao exercício a que elas obrigam para definir as estratégias que melhor conduzam a empresa ao sucesso e à maior criação de valor para o acionista. “Building the financial model forces the manager to think through the

relationships and consequences of investment and financing decisions.” (Fabozzi-Peterson,2003)

O processo de previsão financeira permite que a empresa tente ter uma imagem mais clara sobre o seu funcionamento e sobre quais as variáveis que mais influenciam o seu desempenho e, portanto, com mais importância na criação de valor. Segundo Vadasz (2005), uma empresa que consiga efetuar previsões financeiras com qualidade e precisão e que as integre numa ótica de Gestão de Desempenho do Negócio (*Business Performance Management - BPM*) consegue:

- Identificar os fatores chave de criação de rendimentos e custos e desenvolver medidas de desempenho apropriadas;
- Encorajar a performance humana em torno dessas medidas-chave de desempenho;
- Planear e orçamentar o desempenho efetivamente, articulando os seus objetivos em termos das medidas chave de performance;
- Estimular (como parte do processo de previsão ou de planeamento) os objetivos ou o desempenho esperado usando cenários baseados nesses fatores;
- Perceber os impactos dos fatores operacionais no seu desempenho financeiro.

Na perspetiva do Grupo e das Unidades de Negócio, a previsão financeira é importante em ambos os níveis. Uma previsão financeira precisa irá ajudar o grupo a:

- Gerir efetivamente as expectativas dos seus investidores;
- Otimizar o financiamento da empresa;
- (Re) alocar os recursos na carteira de cada unidade de negócio para melhor gerir o desempenho futuro;
- Rever regularmente o desempenho dos gestores de cada unidade de negócio.

Ao nível das Unidades de Negócio, a previsão financeira ajuda a:

- Alinhar as funções e os processos chave do negócio para garantir que as previsões das vendas (lado da procura) estão corretamente cobertas pelas necessidades das operações (lado da oferta);
- Gerir e monitorizar proactivamente o desempenho dos fatores chave de valor, a rentabilidade e os *cash-flows*.

2.2.1. Qualidade e precisão das previsões financeiras

Num mundo pós crise do *subprime* e em plena crise dos défices orçamentais europeus, as previsões dos economistas são, uma vez mais, o centro das atenções. Contudo, “An economist is an expert who will know tomorrow why the things he predicted yesterday didn’t happen today (Laurence, 1977).”

Assim, a precisão dos modelos económicos e financeiros não parece ser uma característica que os acompanha, não só pelo facto de os modelos serem uma representação matemática da realidade limitados a um conjunto de pressupostos (Derman-Wilmott, 2009), mas também pelo facto da alteração desses pressupostos ao longo do tempo enviesarem as projeções (De Masi, 1996).

Esta imprecisão dos modelos não se deve, aparentemente, a uma falta de investigação na área, nem por falta de interesse no aumento da precisão dos modelos. De acordo com um inquérito realizado por Carbone et al. (1982) a 75 profissionais e 70 académicos, sobre quais os critérios mais importantes para a seleção de um método de previsão, 86% dos inquiridos respondeu a precisão das previsões obtidas, reforçando a ideia de que a precisão dos modelos de previsão financeira é uma das principais preocupações tanto da perspetiva da investigação como do mundo prático.

Contudo, a previsão financeira não é uma ciência exata. Existem autores que defendem que a previsão financeira tem tanto de ciência, no sentido que a utilização de ferramentas estatísticas invariavelmente melhora a precisão das previsões, como de arte, na perspetiva da subjetividade inerente à escolha de pressupostos por parte do utilizador (Evans, 2003). Neste âmbito, Derman e Wilmott (2009), reforçaram esta ideia quando em Janeiro de 2009 redigiram, em resposta à crise de 2007 do *subprime*¹ o Manifesto dos Modelizadores Financeiros (*The Financial Modelers’ Manifesto*), expressando, entre outras reflexões, um dos problemas de base da Teoria Financeira.

Financial theory has tried hard to emulate the style and elegance of physics in order to discover its own laws. But markets are made of people, who are influenced by events, by their ephemeral feelings about events and by their expectations of other people's feelings. The truth is that there are no fundamental laws in finance. And even if there were, there is no way to run repeatable experiments to verify them. (Derman & Wilmott, 2009)

¹ Para mais informação sobre a crise do *subprime* ver, por exemplo, Gorton (2007).

Existem vários métodos para aumentar a precisão das previsões financeiras. Estes métodos podem ser divididos em três grupos²:

- Métodos Qualitativos
 - a) Reuniões de consenso;
 - b) Sistema de Incentivos.
- Métodos Quantitativos
 - c) Combinação de previsões.
- Métodos Híbridos
 - d) Sistema de revisão e monitorização da previsão financeira.

a) *Reuniões de Consenso*

Num estudo realizado por Jain-Malehorn (2006), 77% das empresas inquiridas afirmaram ter este tipo de reuniões. O objetivo consiste na revisão e apreciação das previsões obtidas por métodos quantitativos em que as previsões obtidas dessas reuniões denominam-se: previsões consensuais.

De acordo com Jain-Malehorn (2006), as razões pelas quais este tipo de reuniões aumenta a qualidade e precisão das previsões são:

- Envolve todos os departamentos do processo de previsão financeira. Quanto maior o número de participantes na reunião, melhor será a previsão obtida.
- A apreciação tem um papel importante no processo de previsão financeira. Não há nenhum modelo que consiga ponderar todas as variáveis.
- As reuniões, ao conjugarem os vários departamentos, fazem com que a empresa opere numa mesma filosofia de previsão.
- Qualquer divergência entre o lado da procura e o da oferta será prontamente identificada e reportada ao planeamento de vendas e produção para serem tomadas as devidas medidas corretivas.

² A lista de métodos utilizados para aumentar a precisão das previsões não é extensiva. O objetivo é fornecer uma ideia geral de alguns dos principais métodos utilizados pelas empresas para a resolução deste problema.

b) *Sistemas de Incentivos*

Um método utilizado para aumentar a precisão das previsões que não depende da revisão do modelo, dos dados utilizados nem da apreciação das previsões, passa por criar um sistema de incentivos ligados à precisão das previsões. O incentivo pode assumir duas formas:

- Monetário (bónus);
- Não monetário (reconhecimento moral por parte da chefia e dos pares).

Tradicionalmente, a equipa de vendas, juntamente com o salário fixo mensal, tem associado um plano de incentivos ligado ao número de vendas mensais, trimestrais, semestrais e/ou anuais. Assim, o funcionário terá um maior incentivo para vender mais. Usando a mesma filosofia, havendo um sistema de incentivos associado à precisão das previsões para os responsáveis pela previsão financeira da empresa, há um maior incentivo em melhorar continuamente a precisão.

c) *Combinação de previsões*

A combinação de dados, mais concretamente a combinação de previsões é algo bastante comum quer no mundo financeiro prático quer no de investigação para o aumento da precisão das previsões.

De acordo com o trabalho de Armstrong (2008) que fez uma revisão da literatura e de estudos empíricos sobre a combinação de previsões, em 30 estudos empíricos, a redução no erro de previsão obtida após a combinação de previsões foi em média 12,5% e em situações ideais, a combinação das previsões foi mais precisa que as suas componentes mais precisas. “Combining forecasts improves accuracy to the extent that the component forecasts contain useful and independent information.” (Armstrong, 2008)

A combinação das previsões é bastante simples e intuitiva. A empresa pode usar quatro ou cinco métodos para a previsão financeira e em vez de selecionar um dos resultados obtidos faz a média ponderada dos diferentes resultados. Armstrong (2009), refere que a ponderação deve ser igual para todos os métodos e que a apreciação qualitativa deve ser evitada na ponderação. O estudo refere ainda que a adição de mais métodos de previsão financeira conduz a rendimentos decrescentes no aumento da precisão, pelo que cinco será o número ótimo.

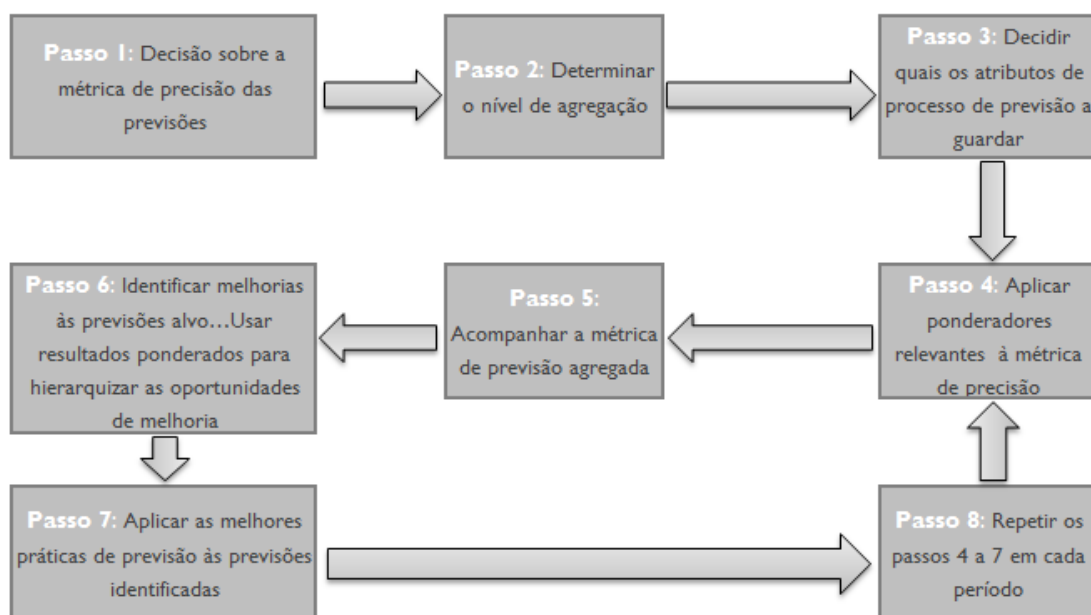
d) *Sistema de revisão e monitorização da previsão financeira*

Independentemente do método de previsão financeira utilizado, só será possível para a empresa melhorar a qualidade e precisão das suas previsões se souber exatamente se o que está a gerar essa imprecisão são os dados, os pressupostos assumidos ou o modelo desenvolvido. Assim, a monitorização e documentação das previsões de forma regular é um processo fundamental para resolver este problema (Jain-Malehorn, 2006).

No sentido de melhorar a qualidade e precisão das previsões, Hoover (2009) desenvolveu oito etapas chave necessárias para uma correta monitorização do processo de previsão financeira conforme ilustrado na Figura 2.2-1.

Figura 2.2-1

Etapas chave no processo de monitorização da previsão financeira



Fonte: Adaptado Hoover (2009)

O objetivo é criar um processo dinâmico que permita à empresa perceber rapidamente quais os fatores que estão a contribuir para a imprecisão das previsões. “Retaining key attributes from your forecasting process provides a ‘forecasting autopsy’, with explanations for failing to meet forecast-accuracy targets – an important aid in identifying the routes to improved forecast accuracy.” (Hoover, 2009)

Ter um sistema de revisão e monitorização do processo de previsão financeira demonstra-se de facto eficaz no aumento da qualidade das previsões, contudo, a empresa

deve ter em conta o custo/benefício que uma previsão mais precisa tem no seu próprio contexto. Em geral, as empresas de maior dimensão terão uma maior facilidade na implementação de sistemas de revisão e monitorização das previsões, bem como na disponibilidade de recursos utilizados no processo de previsão. Tipicamente as empresas de maior dimensão têm departamentos de controlo financeiro e de gestão perfeitamente articulados com uma gestão apoiada em indicadores chave de desempenho (*Key Performance Indicators – KPI*), sendo, tradicionalmente, esses os departamentos responsáveis pela criação e desenvolvimento da previsão financeira (Chenhall, 2003).

Assim, na realidade de uma Pequena e Média Empresa (PME³), a disponibilidade de recursos bem como o grau de especialização e divisão do trabalho pode não potenciar a utilização de sistemas de revisão e monitorização das previsões para resolução do problema da precisão.

2.2.2. Impacto interno e externo da previsão financeira

A noção de que a informação em geral tem impactos no mercado bolsista e que de facto importa para a tomada de decisão dos investidores, já é amplamente aceite desde os anos 70, essencialmente devido ao famoso artigo de 1970 de Eugene Fama denominado “*Efficient Capital Markets: A Review of Theory and Empirical Work*”. Segundo Fama (1970) há três tipos de eficiência de mercado:

- Eficiência fraca, cujos preços refletem apenas toda a informação passada e desta forma seria impossível obter lucros com base em estudos que recorrem a dados históricos;
- Eficiência semi-forte, em que os preços refletem toda a informação histórica e publicamente disponível como os anúncios dos resultados;
- Eficiência forte, em que os preços refletem toda a informação histórica, publicamente disponível e ainda informação privada tornando impossível obter ganhos com *insider trading*⁴.

³ Para mais informações sobre a definição de PME ver a Recomendação 2003/361/CE em http://www.eicpme.iapmei.pt/eicpme_art_03.php?actual=0&temaid=24&temasubid=176&id=435

⁴ *Insider trading* pode significar conduta legal e ilegal. Neste contexto, o termo implica a compra e venda de activos com base em informação privada sobre o activo.

Os testes empíricos à Teoria da Eficiência dos Mercados conduzem à conclusão de que os mercados não são perfeitos, mas são eficientes na forma semi-forte. Desta forma, a única variável que gera alterações no comportamento das ações é a chegada de nova informação ao mercado.

Há uma crescente preocupação externa no que diz respeito à qualidade e precisão da previsão financeira. Essa preocupação teve na origem do *Sarbanes and Oxley Act*⁵ (SOX) em 2002 nos Estados Unidos. Porém já antes, em 1999, no Reino Unido, o *Financial Reporting Council* tinha publicado o relatório - *Internal Control: Guidance for Directors on the Combined Code* – também conhecido como *Turnbull Report*. Este relatório, feito em concordância com a *London Stock Exchange* para as empresas cotadas não era mais do que um conjunto de boas práticas no que diz respeito ao controlo interno e ao reporte financeiro que se esperava que rapidamente se difundisse pelas empresas.

De acordo com um estudo trimestral conduzido pela *Parson Consulting*, a percentagem de empresas pertencentes ao índice S&P 500 que falharam as projeções dos seus analistas por pelo menos 10% baixou para 29,7% no terceiro trimestre de 2004, tendo sido o resultado mais baixo durante os 18 meses em que a empresa de consultoria esteve a realizar o estudo. (Revista Capital Aberto, 2005)

Tendo em conta os objetivos da previsão financeira para a equipa de gestão, as projeções divulgadas para o mercado podem ajudar os investidores a perceber a capacidade da equipa de gestão em alcançar os seus objetivos. Assim, os resultados operacionais previstos vão ser examinados e comparados com os efetivos pelos investidores e analistas e valores bastante díspares ou desfavoráveis poderão ser prejudiciais para a empresa e para o comportamento das suas ações em bolsa (Vadasz, 2005). Estas diferenças afetam significativamente a confiança dos investidores podendo ainda afetar as suas perceções sobre a qualidade da equipa de gestão e da sua competência ao nível da gestão do modelo de negócio, ou do entendimento do mercado onde opera (Vadasz, 2005).

<http://www.sec.gov/answers/insider.htm>

⁵ A lei Sarbanes-Oxley é uma lei norte-americana, assinada em 30 de Julho de 2002. O seu nome deriva dos seus patrocinadores, o Senador Paul Sarbanes e o deputado Michael Oxley. A lei foi criada como uma reação a uma série de escândalos em grandes empresas (por exemplo: Enron, Tyco e WorldCom) com sérias repercussões na bolsa e na confiança dos investidores.

http://en.wikipedia.org/wiki/Sarbanes%E2%80%93Oxley_Act

Ao nível interno, uma previsão financeira imprecisa pode prejudicar seriamente o normal funcionamento da empresa. Tipicamente, um dos aspectos fundamentais no processo de previsão financeira, senão o mais importante, é a previsão das vendas. Num estudo a executivos norte-americanos, Dalrymple (1975) constatou que 93% dos inquiridos disseram que a previsão das vendas era um dos aspectos ou o aspecto mais importante no sucesso das suas empresas.

Assim, uma previsão das vendas imprecisa pode, caso o mercado expanda mais do que a empresa inicialmente antecipou, impedir que a empresa consiga satisfazer toda a procura pelos seus produtos, obrigando a que os consumidores comprem os produtos disponíveis da concorrência, afetando profundamente a quota de mercado da empresa. (Besley-Brigham, 2011).

Contrariamente, se as previsões das vendas forem demasiado otimistas, a empresa pode acabar por ficar com elevados inventários que por sua vez vão traduzir-se em baixos rácios de rotatividade de existências, elevados custos de depreciação e de armazenamento e a possibilidade de ter de abater inventário obsoleto ou inutilizável. Tudo isto, traduzir-se-á numa baixa Rentabilidade dos Capitais Próprios (ROE) o que, consequentemente, irá reduzir o valor das ações da empresa. (Besley-Brigham, 2011)

Podemos, portanto, depreender que uma previsão financeira imprecisa, pode gerar um ciclo vicioso de consequências internas e externas.

2.3. Métodos de previsão financeira

Existem diversas metodologias para se efetuarem previsões financeiras. De acordo com o trabalho de Chambers, et al. (1971), existem vários fatores que influenciam a escolha da técnica de previsão financeira a utilizar, nomeadamente:

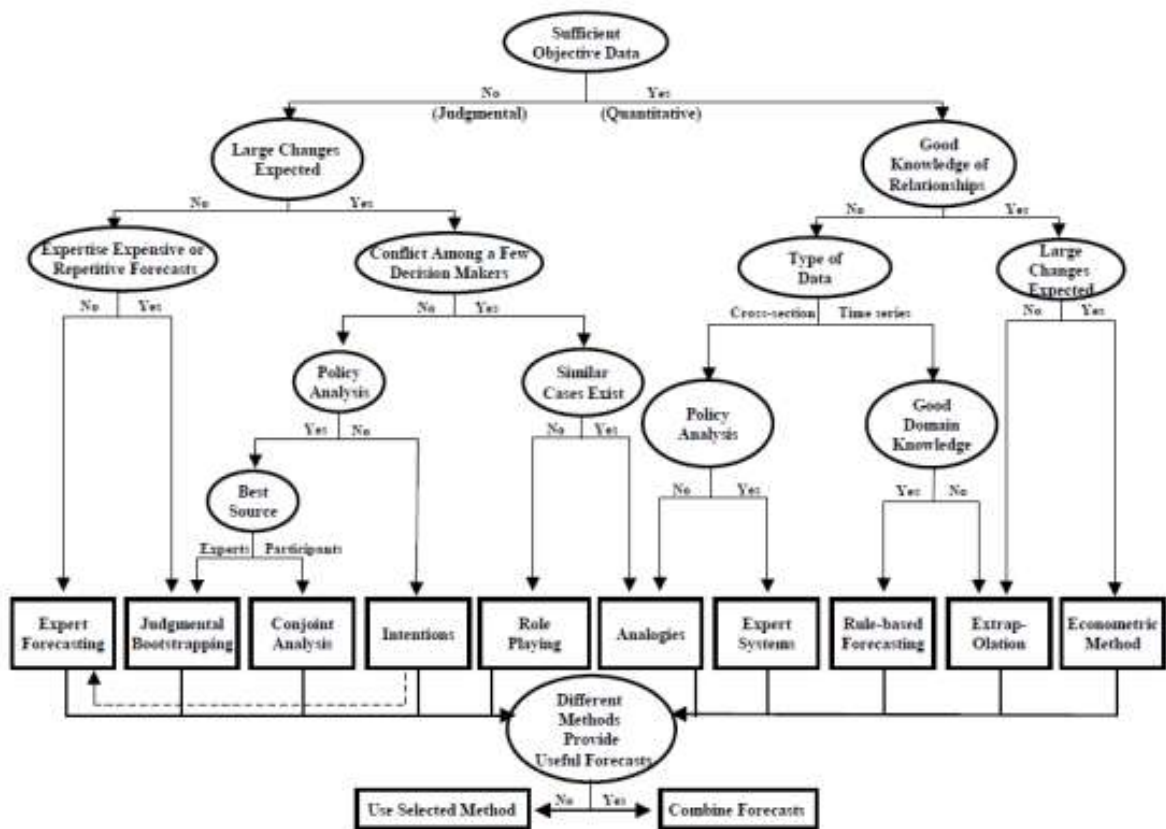
- O contexto da previsão;
- A relevância e disponibilidade de dados históricos;
- O grau de precisão pretendido;
- O horizonte temporal da previsão;
- O custo/benefício da previsão para a empresa;
- Tempo disponível para realizar a análise.

Armstrong (2009) utiliza uma árvore de seleção, apresentada na Figura 2.3-1, para ilustrar como poderá ser feita a escolha entre os vários métodos de previsão, tendo em conta três aspetos fundamentais:

- Disponibilidade de dados;
- Conhecimento sobre as relações estabelecidas entre as variáveis;
- Expectativa de grandes alterações.

Figura 2.3-1

Árvore de Seleção para métodos de previsão



Fonte: Armstrong (2009)

Contudo, podemos organizar as diferentes técnicas utilizadas em 3 categorias:

- Modelos qualitativos:
 - Modelo Delphi;
 - Inquéritos sobre a opinião dos consumidores;
 - Força de vendas;
 - Opinião de um painel de peritos.

- Modelos Quantitativos (análise de séries temporais):
 - Suavização exponencial;
 - Médias Móveis;
 - Box-Jenkins;
 - X-11;
 - Projeção média;
 - Modelos auto-regressivos integrados com médias móveis (ARIMA);
 - Auto-regressão vetorial.
- Modelos Causais
 - Modelos de regressão;
 - Modelos econométricos;
 - Inquéritos de intenção de compra e de antecipação;
 - Modelo Input-output;
 - Análise de ciclo de vida.

Uma técnica de previsão financeira que habitualmente não é mencionada em artigos como o de Chambers et al. (1971) é o método da percentagem das vendas. Um método simples e encontrado muitas vezes em manuais técnicos⁶ que consiste em estimar os gastos, ativos e passivos do período futuro em termos de percentagem das vendas.

No caso de ser aplicado ao ativo fixo económico, este método pressupõe que a empresa está a utilizar 100% da sua capacidade produtiva, pelo que um aumento nas vendas requer um investimento adicional. Como as variáveis não diretamente ligadas às vendas, como a dívida de longo prazo, são iguais no período presente e futuro, após as projeções das outras contas há uma diferença entre o total do ativo e o total do passivo mais o capital próprio. Essa diferença é a necessidade de financiamento da empresa para o período futuro (Shim-Siegel, 2008a).

Tendo em conta os fatores que influenciam a escolha de uma técnica de previsão financeira, podemos inferir que poderá existir alguma ligação entre as técnicas utilizadas e a dimensão da empresa. Assim, empresas mais pequenas tenderão a optar por métodos mais simples e empresas de maior dimensão por métodos mais complexos. Na realidade do tecido empresarial português, caracterizado maioritariamente por PME (INE, 2010),

⁶ Por exemplo *Handbook of Financial Analysis, Forecasting and Modeling* por Shim J.K. e Siegel J.G. ou *Corporate controller's handbook of financial management* por Shim J.K., Siegel J.G. e Dauber.N.

podemos deduzir que grande parte das empresas que faz previsão financeira deve optar por modelos menos sofisticados.

Um estudo realizado por Dalrymple (1987) a 134 empresas norte-americanas concluiu que 44,8% das empresas inquiridas utilizavam regularmente o método qualitativo da força de vendas para obter previsões das vendas, enquanto apenas 11,9% utilizavam métodos econométricos. O estudo indica que as empresas inquiridas dão elevada importância à experiência e conhecimento de pessoas diretamente ligadas ao processo de venda em detrimento de previsões criadas por analistas baseados em estudos econométricos. Esta realidade não implica que as previsões econométricas sejam menos precisas que as de opinião, aliás, Armstrong (2009) diz “Forecasters use expert opinions even when ample evidence exists that other methods are more accurate (...)”.

Yokum-Armstrong (1995) estudaram quais os critérios utilizados para selecionar uma técnica de previsão financeira. O estudo consistiu num inquérito a 94 investigadores, 55 académicos, 133 profissionais e 40 executivos e concluíram que nos quatro universos de pessoas inquiridas o critério mais importante foi a precisão, seguido do tempo necessário para se obter uma previsão e poupança resultante de melhores decisões.

Podemos concluir que o critério mais importante para seleção de uma técnica de previsão financeira é a precisão das previsões e que as empresas na prática dão maior importância a métodos de previsão financeira menos sofisticados. Porém, a pesquisa no aumento de precisão dos modelos financeiros passa pela área da econometria e na criação de modelos complexos, como a utilização de modelos de redes neuronais para efetuar previsões (Armstrong, 2011).

A utilização de dados setoriais no processo de previsão financeira é um tema pouco abordado pela investigação. Na nossa opinião, um modelo de previsão financeira simples, com recurso a dados setoriais pode contribuir para o aumento da precisão das previsões sem que seja necessário complicar o modelo. A existência de fontes informáticas estatísticas que divulgam informação sobre os vários setores da economia, possibilita o uso rápido e fácil deste tipo de dados pelas empresas.

“Do not use complex methods; they do not improve accuracy and the added complexity can cause forecasters to overlook errors and to apply methods improperly.” (Armstrong, 2011)

3. Modelos de Previsão Financeira

Na secção anterior analisamos a importância da previsão financeira para a condução do negócio por parte da equipa de gestão. Definimos, no âmbito deste estudo, o que se entende por previsão financeira e fizemos a distinção entre ela e a orçamentação.

Na secção que se segue vamos analisar como as empresas fazem previsão financeira e que tipos de modelos utilizam. Vamos analisar os métodos e técnicas mais utilizadas para a modelização financeira, nomeadamente através de folhas de cálculo do *Microsoft Excel*®. Vamos ainda abordar os métodos mais comuns de fazer previsão financeira, fazendo a distinção entre modelos qualitativos, causais e de séries temporais.

3.1. Modelização financeira

É devido à incerteza do futuro que as previsões financeiras são tão importantes. “If you cannot control it, then measure it in order to forecast or predict it.” (Arsham, 1994). A capacidade de antecipar as necessidades futuras da empresa é alcançada através da utilização de modelos financeiros que, conjugados com as previsões obtidas, possibilitam que a equipa de gestão consiga perceber como as variáveis endógenas e exógenas à empresa influenciam os resultados finais.

Podemos definir um modelo financeiro como sendo um sistema de equações matemáticas, lógica e dados que descrevem as relações existentes entre as variáveis financeiras e operacionais (Shim-Siegel, 2006).

Alguns exemplos de equações matemáticas presentes nos modelos financeiros são as equações de definição (*definitional equations*). Estas equações são na realidade regras contabilísticas, como por exemplo:

$$\textit{Total do Activo} = \textit{Capital Próprio} + \textit{Passivo} \quad (3.1-1)$$

$$\textit{Resultado Operacional} = \textit{Proveitos Operacionais} - \textit{Custos Operacionais} \quad (3.1-2)$$

Assim, os modelos financeiros são construídos a partir da informação contabilística histórica, presente e futura da empresa. A relação contabilística existente entre as

variáveis presentes nos mapas contabilísticos é automatizada via a utilização de equações matemáticas que as determinam. As finanças, enquanto ciência que estuda como os agentes económicos alocam recursos ao longo do tempo (Fama-Miller, 1972), fundamenta-se na informação contabilística, pelo que a análise financeira da empresa utiliza a mesma informação contabilística, sendo apenas necessário incluir as equações matemáticas que determinam os indicadores financeiros pretendidos pela equipa de gestão.

Além das equações de definição, os modelos financeiros podem também incluir equações comportamentais (*behavioral equations*) que descrevem o comportamento da empresa com respeito a atividades específicas sujeitas a testes e validação empírica (Shim-Siegel, 2006). Podemos descrever as vendas de uma empresa como sendo:

$$Vendas = f(P, PUB, RC, PIB, Pc) \quad (3.1-3)$$

Assim, estamos a definir as vendas da empresa em função dos fatores preço (P), gastos em publicidade (PUB), rendimento do consumidor (RC), produto interno bruto (PIB), preço dos produtos da concorrência (Pc).

Assumindo uma relação linear entre as variáveis, podemos especificar o modelo como sendo:

$$Vendas = a + bP + cPUB + dRC + ePIB + fPc + u \quad (3.1)$$

Em que u é o termo de perturbação aleatório.

Tendo informação sobre o valor de todas as variáveis do modelo, podemos estimar o valor dos parâmetros a , b , c , d , e , e f através da regressão linear. Utilizando depois testes de significância individual a cada parâmetro e de significância global do modelo, podemos identificar quais as variáveis que mais influenciam cada produto específico da empresa. Podemos ainda utilizar estas equações para, via variação das variáveis que o compõe, fazer uma análise de cenários. Por exemplo, a equipa de gestão poderá querer saber qual o impacto de um aumento ou diminuição do preço dos produtos concorrentes nas vendas da empresa.

3.2. Construção de modelos financeiros

O método de construção de um modelo financeiro e o processo de escolha e organização das variáveis de *input* e *output* a considerar no modelo é vasto e subjetivo.

Alguns fatores que influenciam este processo são:

- Objetivo do modelo;
- Tipologia do modelo;
- Grau de conhecimento económico e informático do utilizador final e do criador do modelo;
- Disponibilidade informática de dados.

Os modelos podem variar muito em termos de complexidade, contudo, alguns manuais técnicos sobre a modelização financeira favorecem uma metodologia – o método K.I.S.S. (*Keep It Simple, Stu...*) (Tjia, 2004).

“KISS is a very beneficial principle to follow. Determine what ‘simple’ means to you and those who will be using your model. If there is a difference, go with the ‘simpler’ of the two. The more you can follow that standard, the more your work will be used.” (Tjia, 2004)

De acordo com Tjia (2004), o método KISS não significa que o modelo deva ser simplista e fazer apenas o mais rudimentar dos cálculos. Em vez disso, significa que em tudo o que se pretende que o modelo faça, deve-se manter as coisas simples e fáceis de interpretar para todos os utilizadores do modelo.

Podemos criar modelos financeiros recorrendo a vários tipos de *software*, porém as folhas de cálculo, popularizadas através do *Microsoft Excel*®, destacam-se de outros programas financeiros. “The electronic spreadsheet has done more than any other product to make the capabilities of microcomputers evident to the business community (Shim-Siegel, 2008b).”

Desta forma e por uma questão de simplicidade e maior familiarização com o programa, neste Trabalho desenvolvemos o nosso modelo utilizando o *Microsoft Excel*®.

A título de exemplo, apresentamos na Figura 3.2-1 um *template* de um modelo financeiro. Conforme podemos constatar, o modelo apresenta o ano de 2010 como passado e o ano

de 2012 como previsual. Os valores para o ano de 2010 e os disponíveis de 2011 são os dados históricos da empresa e podemos considera-los como *inputs*, enquanto para o ano de 2012 há a necessidade de se efetuarem previsões das diversas variáveis que, com a ajuda do *Microsoft Excel*® e de um conjunto de pressupostos assumidos pelo utilizador, o próprio modelo preenche os valores em falta.

Figura 3.2-I

Demonstração de Resultados Previsual

Demonstração de Resultados Previsual	2010	2011	2012
Volume Negócios	0	0	0
Custos fixos (exceto amortizações)	0	0	0
Custos variáveis	0	0	0
Custos indiretos	0	0	0
Provisão custos pós encerramento	0	0	0
Resultado da Atividade (EBITDA)	0	0	0
Margem EBITDA % Vendas	0,00%	0,00%	0,00%
Amortizações do exercício imobilizado corpóreo	0	0	0
Amortizações do exercício imobilizado incorpóreo	0	0	0
Resultado Operacional (EBIT)	0	0	0
Margem EBIT % Vendas	0,00%	0,00%	0,00%
Encargos Financeiros de Financiamento	0	0	0
Resultado Antes Impostos	0	0	0
Imposto sobre o rendimento do exercício	0	0	0
Resultado Líquido	0	0	0
Distribuição de resultados	0	0	0
Resultado Retido	0	0	0

A construção de um modelo financeiro está diretamente ligada à sua finalidade. De acordo com Shim e Siegel (2006), tendo em conta o seu objetivo, podemos dividir os modelos financeiros em dois tipos:

- Modelos de simulação (modelos *what-if*) - como o próprio nome indica, servem para simular vários tipos de cenários e fazer análises de sensibilidade. Este tipo de análises permite que a equipa de gestão perceba o impacto da variação das variáveis, tanto endógenas como exógenas, no desempenho da empresa. Contudo, estes modelos são utilizados essencialmente para analisar os efeitos de políticas de gestão alternativas e da alteração dos pressupostos do ambiente externo da empresa;

- Modelos de otimização - Os modelos de otimização são utilizados para maximizar ou minimizar um ou mais objetivos previamente estabelecidos.

Os modelos podem ainda ser determinísticos ou probabilísticos. Os modelos determinísticos não incluem nenhuma variável aleatória ou probabilística, enquanto os modelos probabilísticos incluem este tipo de variáveis, por exemplo, para o cálculo das vendas ou dos custos.

Identificado o objetivo principal do modelo financeiro e escolhido o software que se vai utilizar na construção do modelo o utilizador deve claramente identificar quais as variáveis de input e de output.

De uma forma genérica e servindo apenas como exemplo, assumindo um modelo desenvolvido em Excel®, com a finalidade de construir os mapas previsionais para o próximo ano – Balanço e Demonstração de Resultados – uma possível estrutura do modelo seria:

- Uma folha de *input*;
- Uma folha de *output* com a Demonstração de Resultados previsional;
- Uma folha de *output* com o Balanço previsional

Na folha de *input* podemos, por exemplo, incluir os Balanços e Demonstrações de Resultados históricos e os pressupostos internos e externos de previsão. As outras duas folhas seriam apenas de *output*, revelando os resultados previsionais fundamentados pelos *inputs* da primeira folha.

3.3. Utilização de modelos financeiros

A difusão da modelização financeira nas empresas enquanto instrumento de apoio à tomada de decisão por parte da equipa de gestão teve o seu crescimento ligado ao crescimento da capacidade computacional dos computadores pessoais. À medida que os computadores se foram desenvolvendo, foi sendo possível criar modelos financeiros capazes de responderem a um crescente número de problemas económicos e/ou financeiros.

De acordo com Shim et al. (2008b), algumas das utilizações dos modelos financeiros são:

- Projetar resultados financeiros de acordo com um conjunto de pressupostos, de forma a avaliar o impacto financeiro da utilização de outros pressupostos e estratégias alternativas e preparar previsões financeiras de longo prazo;
- Calcular receitas, custos operacionais, *cash-flows* e rácios mensais para um horizonte temporal de 5 anos;
- Análise de cenários e calendarização financeira;
- Efetuar previsões do Balanço e Demonstração de Resultados com análises de cenários;
- Projetar necessidades de financiamento;
- Análise de cenários baseada nas previsões das vendas;
- Gerar relatórios de desempenho de vários centros de lucro/custo;
- Projetar as implicações financeiras de vários programas de investimento;
- Estudar o impacto de alterações no volume de produção no orçamento e no *cash-flow*;
- Fazer previsões dos custos e receitas por divisão e por mês;
- Efetuar análises estatísticas, como por exemplo: comparação das vendas atuais com as previstas no sentido de avaliar o desempenho a nível de cada unidade de negócio;
- Analisar o impacto de processos de fusão e aquisição;
- Avaliar o potencial económico de novos investimentos e produtos.

4. Desenvolvimento do modelo

4.1. Objetivo do estudo e desenvolvimento das hipóteses

Apesar de existirem várias análises setoriais na gestão⁷ e de através da existência delas ser reconhecida a importância dos dados do setor para avaliação e comparação do desempenho da empresa, no que diz respeito à previsão financeira, não é conhecido pelos autores nenhum estudo empírico que teste se de facto os dados setoriais podem ou não tornar a previsão financeira mais precisa.

No mercado de ações, encontramos inúmeros estudos sobre a avaliação e a previsão do valor das ações, por exemplo Sharpe (1964), Cochrane (2000), Fama-French (2004). Um desses estudos, nomeadamente o de Sharpe (1964) trouxe uma nova perspectiva no que toca a avaliação de ativos, dando origem ao Modelo de Avaliação de Ativos Financeiros (CAPM – *Capital Asset Pricing Model*). Este modelo estabelece que, em equilíbrio, o retorno esperado de um ativo é:

$$E_s = r_f + \beta(E_m - r_f) \quad (4.1-1)$$

Em que r_f é a taxa de juro sem risco, E_m é o retorno esperado da carteira de mercado e β é o coeficiente de correlação entre o retorno do ativo e o retorno do mercado⁸.

Como se pode constatar da equação acima transcrita, o retorno esperado da ação não depende em grande parte de si própria, mas antes do mercado e da sua relação com o mercado, além da taxa de juro sem risco.

Perold (2004) diz que, segundo o modelo CAPM:

(...) a stock's expected return does not depend on the growth rate of its expected future cash flows. To find the expected return of a company's shares, it is thus not necessary to carry out an extensive financial analysis of the company and to forecast its future cash flows.

Seguindo este pensamento e refletindo-o no nosso tema de investigação, não terão os dados do setor uma maior capacidade preditiva do que os dados da própria empresa, em termos do processo de previsão financeira do desempenho futuro da empresa? Se sim,

⁷ Como por exemplo: SWOT, PEST e Cinco Forças de Porter.

⁸ Para mais pormenores sobre o modelo, ver por exemplo Sharpe (1964) e Perold (2004).

em que situações tal se verifica? Será a sua utilização melhor em termos gerais ou mais específicos?

Neste âmbito, o principal objetivo deste estudo é o de perceber o impacto da utilização de dados setoriais no processo de previsão financeira e em que situações os resultados do processo de previsão financeira são mais precisos com dados do setor do que com dados da própria empresa.

Para melhor percebermos o impacto da utilização de dados setoriais na previsão financeira do desempenho futuro da empresa, decidimos fazer a previsão do indicador de eficiência Retorno Operacional do Ativo (ROA).

A utilização de indicadores como o ROA na previsão financeira é particularmente útil na medida em que estes indicadores permitem captar as relações que se estabelecem entre as variáveis das demonstrações financeiras, sendo mais fácil de prever do que as variáveis isoladamente (Schill, 2005).

Desta forma, desenvolvemos as seguintes hipóteses a serem testadas:

H1: A utilização exclusiva de dados setoriais no processo de previsão financeira obtém, em geral, previsões do ROA mais precisas do que aquelas obtidas via uso exclusivo de dados da própria empresa.

H2: A combinação, a ser utilizada no processo de previsão financeira, entre dados setoriais e da própria empresa, obtém, em geral, previsões do ROA mais precisas do que aquelas obtidas via uso exclusivo de um só conjunto de dados.

H3: A utilização exclusiva de dados setoriais no processo de previsão das vendas obtém, em geral, previsões mais precisas do que aquelas obtidas via uso exclusivo de dados da própria empresa ou de dados combinados.

H4: A utilização de dados subsetoriais no processo de previsão financeira, obtém, em geral, previsões do ROA mais precisas do que aquelas obtidas via a utilização exclusiva de dados setoriais ou da própria empresa.

H5: A precisão das previsões do ROA, obtidas via uso exclusivo de dados da empresa, está inversamente relacionada com a dimensão da empresa.

4.2. Escolha e desenvolvimento do modelo de previsão financeira

a) Modelo utilizado e horizonte temporal

O tecido empresarial português é, na sua grande maioria, constituído por PME, que representavam 99,7% das sociedades do setor não financeiro em 2008. Do total de PME, as microempresas⁹ predominavam, representando cerca de 86% (INE, 2010). Desta forma, escolhemos um modelo simples – método da percentagem das vendas - para o processo de previsão financeira. Pensamos que este modelo se enquadra melhor numa perspetiva de previsão financeira para apoio à tomada de decisão da equipa de gestão na realidade de uma PME portuguesa (Armstrong, 2009). O software utilizado para construção do modelo foi o *Microsoft Excel*®.

A previsão do indicador ROA teve a seguinte base de cálculo:

$$\mathbf{ROA: Rentabilidade Operacional do Activo} = ROVN \times GRA \quad (4.2-1)$$

Em que,

$$\mathbf{ROVN: Rentabilidade Operacional do Volume de Negócios} = TMB \times ECC \quad (4.2-2)$$

$$\mathbf{GRA: Grau de Rotação do Activo} = \frac{\text{Volume de Negócios}}{\text{Activo Corrigido}} \quad (4.2-3)$$

$$\mathbf{TMB: Taxa de Margem Bruta} = \frac{\text{Margem Bruta}}{\text{Volume de Negócios}} \quad (4.2-4)$$

$$\mathbf{ECC: Efeito de Controlo de Custos} = \frac{\text{Resultado Operacional}}{\text{Margem Bruta}} \quad (4.2-5)$$

Assim, para o cálculo do ROA necessitamos de quatro variáveis:

- Três da Demonstração de Resultados, assinaladas a negrito na Tabela 4.2-1
- Uma do Balanço – Activo Corrigido – definido na equação 4.2-6.

⁹ Para uma empresa ser considerada micro, de acordo com a Recomendação 2003/361/CE, deve, cumulativamente, ter um número de efetivos inferior a 10 trabalhadores, volume de negócios inferior ou igual a 2.000.000€ e um balanço total inferior ou igual a 2.000.000€.

http://www.eicpme.iapmei.pt/eicpme_art_03.php?actual=0&temaid=24&temasubid=176&id=435

Tabela 4.2-1: Demonstração de Resultados

(+)	Volume de Negócios (VN)
(-)	Custo das Mercadorias Vendidas
<hr/>	
(=)	Margem Bruta (MB)
(-)	Outros Custos Operacionais
<hr/>	
(=)	Resultado Operacional (RO)

$$AC: \text{Activo Corrigido} = \text{Activo} - \text{Passivo não financeiro} \quad (4.2-6)$$

A base de cálculo das previsões para o ano de 2009 das quatro variáveis foi:

i) Volume de Negócios 2009

$$VN\ 2009 = VN\ 2008 \times (1 + \text{média das taxas de crescimento anual de 2007 e 2008}) \quad (4.2-7)$$

ii) Margem Bruta 2009

$$MB\ 2009 = VN2009 \times \text{média da \% de vendas de 2006, 2007 e 2008 da MB} \quad (4.2-8)$$

iii) Resultado Operacional 2009

$$RO\ 09 = VN\ 2009 \times \text{média da \% de vendas de 2006, 2007 e 2008 do RO} \quad (4.2-9)$$

iv) Ativo Corrigido 2009

$$AC\ 2009 = AC\ 2008 \times (1 + \text{média das taxas anuais de crescimento 2006, 2007 e 2008}) \quad (4.2-10)$$

Para testar as cinco hipóteses dentro da perspectiva de previsão financeira desenvolvida neste estudo, optamos por fazer a previsão do indicador ROA recorrendo a cinco conjuntos de dados:

1°. Dados históricos da empresa (**E**);

- Cálculo das médias de percentagem das vendas e de crescimento com recurso exclusivo aos dados da própria empresa.

2°. Dados históricos do setor (**S**);

- Cálculo das médias de percentagem das vendas e de crescimento com recurso exclusivo a dados setoriais.

3°. Combinação de dados históricos da empresa e do setor 1ª fase **(C1)**;

- Cenário base: cálculo das variáveis ii), iii) e iv) foi feito com recurso aos dados do primeiro conjunto e a variável i) foi calculada com recurso aos dados do segundo conjunto.

4°. Combinação de dados históricos da empresa e do setor 2ª fase **(C2)**;

- Teste de robustez: cálculo das quatro variáveis utilizou uma média das médias da empresa e do setor.

5°. Dados históricos subsetoriais **(SS)**.

- Ordenamos as empresas da amostra por ordem decrescente em termos de dimensão, utilizando como critério o valor da conta Ativo Corrigido. De seguida, dividimos a amostra ordenada por quintis em que os primeiros quatro quintis contêm 58 empresas da amostra e o último contém 59. A cada quintil irá corresponder um subsetor. Desta forma, usamos os dados de cada um dos cinco subsetores criados para calcular as previsões de cada empresa dentro de cada subsetor. O cálculo de cada uma das quatro variáveis foi idêntico ao dos outros conjuntos, porém, as taxas de crescimento, a percentagem das vendas e as médias calculadas dizem respeito apenas a cada subsetor, tendo sido apenas utilizadas no subsetor a que correspondem.

Relativamente ao horizonte temporal, consideramos como passado o intervalo de tempo entre os anos de 2005 a 2008¹⁰ e como futuro o ano de 2009. Desta forma, os dados de 2009 não entraram para o cálculo de nenhuma das metodologias, servindo apenas para comparar os resultados obtidos dos quatro conjuntos de dados em termos de precisão.

b) Amostra

A amostra inicial era composta por dados contabilísticos de 336 empresas Portuguesas do setor do fabrico de calçado, representando cerca de 24,96% do total de empresas do setor em 2009 (APICCAPS, 2010), para o horizonte temporal de 2005 a 2009.

¹⁰ Importa realçar que a variável AC tem dados disponíveis de 2005 a 2009, mas as variáveis VN, MB e RO só têm dados disponíveis de 2006 a 2009.

O setor do calçado foi escolhido pelas seguintes razões:

- Setor industrial e, portanto, com grande peso dos ativos no balanço das empresas, proporcionando a utilização de indicadores de eficiência;
- Elevada maturidade do setor em Portugal, apesar de alguma oscilação na produção desde o início do século devido essencialmente à adesão da China à Organização Mundial do Comércio e a queda das últimas barreiras ao comércio internacional (APICCAPS, 2010);
- Disponibilidade de dados, retirados da base de dados SABI (Sistema de Análise de Balanços Ibérico) e grande quantidade de informação disponível na internet no site da APICCAPS¹¹;
- Elevada homogeneidade do setor sendo este predominantemente dominado por PME.

Após a análise da amostra inicial, foram excluídas algumas empresas por criarem alguns problemas estatísticos, nomeadamente a geração de *outliers*¹². Desta forma, foram retiradas¹³ da amostra empresas que apresentassem um valor nulo em qualquer ano do horizonte temporal da amostra para qualquer uma das quatro variáveis anteriormente referidas.

A existência na amostra de empresas com dificuldades financeiras e/ou operacionais enviesava os resultados deste estudo, não só pelo facto já referido de geração de *outliers*, mas, também, por não ser objetivo deste estudo a análise de um caso tão particular como as empresas em estado de falência ou outra qualquer dificuldade económica.

Assim, reduzimos o número total de empresas da amostra para 291, representando cerca de 21,61% do total do setor em 2009.

¹¹ <http://www.apiccaps.pt>

¹² “An outlier is a data object that deviates significantly from the rest of the objects (...) (Han et al., 2011)”

¹³ Algumas empresas apresentavam valores nulos ou próximas de 0 nestas variáveis a meio do horizonte temporal da amostra, criando taxas de crescimento anuais exponenciais, enviesando os resultados do estudo.

5. Análise de resultados

Na secção que se segue, analisamos as previsões do indicador ROA obtidas com recurso aos cinco conjuntos de dados utilizados. A secção está organizada da seguinte forma:

- 1°. Definimos o conjunto de medidas de precisão das previsões que utilizamos para avaliar qualitativamente os diferentes conjuntos de dados.
- 2°. Analisamos os resultados globais para o total da amostra dos quatro primeiros conjuntos de dados utilizados (E, S, C1 e C2).
- 3°. Dividimos a amostra por quintis, ordenados por ordem decrescente em termos de dimensão da empresa, utilizando como critério o valor da conta Ativo Corrigido, de forma a captarmos melhor o impacto da utilização dos dados dentro do setor. Desta forma, pretendemos apurar se os resultados globais se mantêm ou se existe alguma ligação entre os dados utilizados para a previsão financeira e a dimensão da empresa.

A Tabela 5-1 apresenta a divisão por quintis da amostra e respetivo significado.

Tabela 5-1

Divisão da amostra por Quintis

Quartil	Nº de Empresas	Significado
1º	58	Líderes do setor
2º	58	Média Alta
3º	58	Média
4º	58	Média Baixa
5º	59	Baixa
Total	291	

É nossa expectativa que o conjunto de dados da própria empresa produza previsões menos precisas que os outros três conjuntos para o primeiro quintil. Este quintil é característico de empresas, tendencialmente, mais estáveis, mais maduras, com baixas taxas de crescimento e que, teoricamente, convergem para os dados do setor.

À medida que a dimensão da empresa for diminuindo ao longo da amostra, a nossa expectativa é que os dados da própria empresa vão melhorando a sua capacidade preditiva das variáveis em causa neste estudo.

4°. Analisamos os resultados obtidos com recurso ao quinto conjunto de dados (subsetoriais), analisando, também, individualmente cada subsetor.

5.1. Medidas de avaliação de precisão das previsões

Após a obtenção dos diferentes resultados de previsão, torna-se necessário medir a diferença entre as previsões e os dados efetivos para o ano de 2009. Assim, utilizamos seis medidas de precisão de previsão, de acordo com o estudo de Gooijer-Hyndman (2005), que têm como base de cálculo o erro de previsão (et) e a percentagem de erro (pt), definidos nas equações 5.1-1 e 5.1-2 respectivamente.

Gooijer-Hyndman (2005) definem como erro de previsão (et) a diferença entre o valor efectivo (Yt) e o valor previsto (Ft) dado pelo modelo.

$$et = Yt - Ft \quad (5.1-1)$$

Desta forma, valores positivos para et indicam que a previsão errou por defeito e valores negativos significam que a previsão errou por excesso.

Como percentagem de erro, Gooijer-Hyndman (2005) definem qual a percentagem que o erro tem no valor de Yt .

$$pt = \frac{100et}{Yt} \quad (5.1-2)$$

Tendo et e pt como base, as outras medidas de precisão de previsão são definidas de acordo com a Tabela 5.1-1.

Tabela 5.1-1

Fórmulas das medidas de precisão de previsão

Medidas de precisão		Fórmula
MSE	Erro Quadrático Médio	= <i>média</i> (e_t^2)
RMSE	Raiz Quadrada do Erro Quadrático Médio	= \sqrt{MSE}
MAE	Erro Absoluto Médio	= <i>média</i> ($ e_t $)
MdAE	Erro Absoluto Mediano	= <i>mediana</i> ($ e_t $)
MAPE	Erro Percentual Absoluto Médio	= <i>média</i> ($ p_t $)
MdAPE	Erro Percentual Absoluto Mediano	= <i>mediana</i> ($ p_t $)

O trabalho de Gooijer-Hyndman (2005) apenas ilustra as medidas de precisão mais utilizadas e referenciadas em trabalhos de investigação. Eles apresentam dezassete medidas no total, das quais escolhemos seis, baseando a nossa escolha no trabalho de Carbone-Armstrong (1982). Este trabalho indica, através do inquérito realizado, que as medidas de precisão baseadas no MSE, MAE e MAPE eram as mais utilizadas tanto por profissionais como por investigadores.

Podemos fazer a seguinte distinção entre as seis medidas de precisão escolhidas, relativamente ao seu propósito:

- MSE
 - RMSE
 - MAE
 - MdAE
- } Medição da amplitude do erro de previsão
-
- MAPE
 - MdAPE
- } Medição do peso relativo do erro de previsão na observação

Vários estudos como por exemplo Collopy-Armstrong (1992), Hyndman-Koehler (2005) e Gooijer-Hyndman (2005) evidenciam algumas desvantagens na utilização destas medidas de precisão relativamente à sua utilização para escolha do método de previsão a ser utilizado em séries temporais. As principais desvantagens enunciadas são:

- As medidas MSE e MAE e suas derivadas são dependentes da escala da amostra e não devem ser utilizadas para comparar métodos com séries temporais de diferentes escalas;
- As medidas MSE e RMSE são mais sensíveis aos *outliers* do que o MAE e o MdAE;
- As medidas MAPE e MdAPE são indefinidas quando $Y_t = 0$ e infinitas quando no limite Y_t é próximo de 0;
- As medidas MAPE e MdAPE penalizam mais os erros por excesso do que os erros por defeito.

Contudo, no que diz respeito ao nosso estudo, estes problemas não são tão relevantes. A escala da amostra é a mesma para todos os conjuntos de dados utilizados, os *outliers* foram retirados por corresponderem a um estudo particular fora do âmbito da nossa investigação e a nossa amostra é em geral composta por empresas em que os valores de

Y_t não estão perto de zero. Além destas razões, o nosso estudo não pretende escolher um método de previsão financeira, mas sim estudar o impacto da utilização de dados setoriais na previsão financeira.

Na nossa opinião, todas as seis medidas proporcionam uma boa imagem do erro médio na amostra e do peso médio do erro na observação, uma vez que não são condicionadas pelas suas limitações estatísticas.

5.2. Resultados globais

5.2.1. Conjunto de dados da empresa e do setor

A análise dos resultados globais das medidas de precisão – ilustrados na Tabela 5.2-1 – sugere que os dados setoriais podem ser importantes no processo de previsão financeira do ROA e que, em determinados casos, se sobrepõe aos dados históricos da empresa.

Tabela 5.2-1
Medidas de precisão das previsões do ROA para o total da amostra (E e S)

Medidas de precisão	E	S	Avaliação
MSE	2,71%	2,26%	S
RMSE	16,47%	15,04%	S
MAE	9,45%	10,60%	E
MdAE	5,62%	7,57%	E
MAPE	219,76%	250,70%	E
MdAPE	57,03%	69,37%	E

Dos resultados apresentados na Tabela 5.2-1 podemos constatar que o MSE com dados do setor é menor do que com dados da empresa, o que indicia que, em média, a amplitude do erro de previsão com dados do setor é menor do que com dados da empresa. Contudo, o MAE e o MdAE, que não penalizam tanto os valores elevados do erro, sugerem que as previsões com dados da empresa são mais precisas.

A variância dos erros de previsão com dados do setor é igualmente menor do que a variância dos erros de previsão com dados da empresa, sendo 2,23% e 2,71% respetivamente o que indica uma menor dispersão dos erros de previsão com dados do setor.

Contudo, para o total da amostra, o erro de previsão com dados da empresa é, em geral, menor do que com dados do setor, conforme ilustrado na Tabela 5.2-2.

Tabela 5.2-2
Número de empresas com previsão do ROA mais precisa por conjunto de dados (E e S)

Conjunto de dados	Nº de Empresas	Porcentagem da amostra
E	172	59,11%
S	119	40,89%
Total da amostra	291	100,00%

Como podemos constatar pela Tabela 5.2-2, aproximadamente 41% da amostra, obteve previsões do ROA mais precisas com recurso exclusivo a dados do setor do que com recurso exclusivo a dados da empresa. Apesar de este valor ser inferior ao resultado obtido com dados da empresa, não é inferior o suficiente para se poder concluir pela não relevância dos dados setoriais para a previsão financeira do ROA. Contudo, e perante os resultados, para o total da amostra, somos obrigados a rejeitar *H1*.

Para percebermos melhor os resultados apresentados, precisamos de detalhar o cálculo do ROA nos quatro indicadores que o determinam. Por sua vez, todos esses indicadores dependem direta ou indiretamente de uma variável: o VN. Antes de analisarmos os resultados das previsões dos quatro indicadores para percebermos que conjunto de dados gera previsões mais precisas, vamos analisar as previsões do VN, que de facto é a variável chave e impulsionadora dos quatro indicadores.

Como podemos constatar pelos resultados das Tabelas 5.2-3 e 5.2-4, tanto as medidas de precisão como o erro de previsão são inferiores com dados do setor. O erro de previsão do VN com recurso a dados setoriais é, aproximadamente, para 66% da amostra, inferior do que com recurso a dados da empresa.

Como se pode observar na Tabela 5.2-3, o MSE, MAE e MdAE são inferiores para os dados do setor, o que significa que a amplitude do erro das previsões com estes dados é inferior à dos dados da própria empresa. Além da amplitude ser menor, o peso do erro de previsão na observação, captado pelas medidas MAPE e MdAPE, é igualmente inferior, reforçando a ideia de uma maior capacidade preditiva da variável VN com recurso a dados setoriais na amostra.

Tabela 5.2-3
Medidas de precisão das previsões do VN para o total da amostra (E e S)

Medidas de precisão	E	S	Avaliação
MSE	5.571.948,31	4.372.150,49	S
RMSE	2.360,50	2.090,97	S
MAE	948,937	761,025	S
MdAE	383,346	276,56	S
MAPE	23,67%	18,27%	S
MdAPE	14,56%	12,20%	S

Tabela 5.2-4
Número de empresas com previsão do VN mais precisa por conjunto de dados (E e S)

Conjunto de dados	Nº de Empresas	Percentagem na amostra
E	100	34,36%
S	191	65,64%
Total da amostra	291	100,00%

Conforme vimos, para o total da amostra, as previsões do indicador ROA são mais precisas com recurso a dados da própria empresa. Contudo, as previsões do VN, a variável chave do nosso modelo, são mais precisas com dados do setor. Estes resultados sugerem que, num setor industrial com elevada maturidade, como o do calçado em Portugal, as taxas de crescimento das vendas de cada empresa convergem para a taxa de crescimento do setor, explicando, portanto, a maior precisão da média setorial de crescimento para prever na amostra as vendas de cada empresa para o ano de 2009.

Para melhor compreendermos o que está a afetar negativamente a previsão do ROA com recurso a dados setoriais, vamos detalhar a previsão dos quatro indicadores, apresentados na Tabela 5.2-5.

Tabela 5.2-5
Medidas de precisão das previsões dos indicadores TMB, ECC, ROVN e GRA para o total da amostra

Medidas de Precisão	TMB			ECC			ROVN			GRA		
	E	S	A	E	S	A	E	S	A	E	S	A
MSE	0,49%	1,77%	E	0,53%	1,22%	E	0,15%	0,35%	E	935,48%	659,53%	S
RMSE	7,00%	13,32%	E	7,25%	11,03%	E	3,89%	5,90%	E	305,86%	256,81%	S
MAE	4,43%	9,60%	E	4,45%	7,17%	E	2,38%	3,69%	E	149,60%	99,40%	S
MdAE	3,10%	7,04%	E	2,47%	4,40%	E	1,29%	2,11%	E	66,87%	48,21%	S
MAPE	8,48%	17,39%	E	195,41%	253,67%	E	190,48%	199,71%	E	43,40%	29,79%	S
MdAPE	6,11%	14,46%	E	35,71%	35,71%	E	36,57%	64,22%	E	27,66%	18,13%	S

Como se pode constatar pelos resultados ilustrados na Tabela de 5.2-5, as previsões dos indicadores TMB, ECC e ROVN são mais precisas com recursos a dados da empresa. Apenas as previsões do indicador GRA são mais precisas com recurso a dados do setor. Podemos ainda constatar que a diferença dos valores das seis medidas de precisão entre as previsões obtidas via dados da empresa e dados do setor é substancial nos quatro indicadores. Estes resultados sugerem que o indicador de eficácia GRA, para a empresas presentes na amostra, converge para os valores setoriais, enquanto os indicadores de eficiência TMB, ECC e ROVN demonstram não convergir para os valores do setor.

Para percebermos o impacto que cada indicador tem no cálculo do ROA, fizemos uma análise de sensibilidade em que variamos, isoladamente, cada uma das quatro variáveis utilizadas em 1% e verificamos qual a respetiva variação percentual em cada um dos quatro indicadores e por fim no ROA. Na Tabela 5.2-6 estão expostos os resultados desta análise.

Tabela 5.2-6
Análise de sensibilidade dos quatro indicadores

Indicadores	Variação de 1%			
	VN	MB	RO	AC
TMB	0,00%	1,00%	0,00%	0,00%
ECC	0,00%	-0,99%	1,00%	0,00%
ROVN	0,00%	0,00%	1,00%	0,00%
GRA	1,00%	0,00%	0,00%	-0,99%
ROA	1,00%	0,00%	1,00%	-0,99%

Conforme podemos observar na Tabela 5.2-6, as variáveis com impacto direto no cálculo do ROA são:

- Volume de Negócios (relação positiva);
- Resultado Operacional (relação positiva);
- Ativo Corrigido (relação negativa).

Para finalizar a análise de sensibilidade, variamos os quatro indicadores para perceber o impacto da variação de cada um no ROA. Importa recordar que, como o indicador ROVN é o produto entre a TMB e o ECC decidimos não o variar isoladamente e optamos por fazê-lo via os seus componentes.

Assim, constatamos que uma variação de 1% em qualquer um dos 3 indicadores, *ceateris paribus*, conduz a uma variação de 1% no ROA no mesmo sentido. Contudo, se variarmos os 3 indicadores simultaneamente 1% no mesmo sentido, o ROA varia 3,03% no mesmo sentido, ou seja, a variação dos 3 indicadores tem um efeito cumulativo na variação do ROA.

5.2.2. Conjunto de dados combinados

Resultados do cenário base da combinação de dados CI

De facto, a inclusão dos dados setoriais na previsão do VN, teve um impacto bastante significativo na precisão das previsões do ROA. Os dados da Tabela 5.2-7 ilustram que com esta combinação de dados, as previsões do ROA são, para mais de metade da amostra, mais precisas que as previsões obtidas com recurso a dados da empresa.

Tabela 5.2-7
Número de empresas com previsão do ROA mais precisa por conjunto de dados (E e CI)

Conjunto de dados	Nº de Empresas	Percentagem na amostra
E	124	42,61%
CI	167	57,39%
Total da amostra	291	100,00%

Como a única diferença entre os dois conjuntos é a previsão do VN, os resultados das medidas de precisão são muito semelhantes. Porém, todas as medidas de precisão apresentam valores inferiores para as previsões via dados combinados, conforme exposto na Tabela 5.2-8.

Tabela 5.2-8
Medidas de precisão das previsões do ROA para o total da amostra (E e CI)

Medidas de precisão	E	CI	Avaliação
MSE	2,71%	2,64%	CI
RMSE	16,47%	16,24%	CI
MAE	9,45%	9,12%	CI
MdAE	5,62%	4,96%	CI
MAPE	219,76%	209,24%	CI
MdAPE	57,03%	53,76%	CI

Como podemos constatar, quer a amplitude do erro quer o peso do erro na observação diminuíram com recurso a dados combinados CI.

Os resultados da Tabela 5.2-9, que compara os resultados das medidas de precisão das previsões para os três conjuntos de dados utilizados, mostram que a amplitude do erro e o peso do erro na observação são, quase sempre, inferiores nas previsões com recurso a dados combinados CI face à precisão das previsões com recurso aos outros conjuntos de dados.

Tabela 5.2-9

Comparação das medidas de precisão das previsões do ROA com recurso aos conjuntos de dados E, S e CI

Medidas de precisão	E	P ¹⁴	S	P	CI	P
MSE	2,71%	3°	2,26%	1°	2,64%	2°
RMSE	16,47%	3°	15,04%	1°	16,24%	2°
MAE	9,45%	2°	10,60%	3°	9,12%	1°
MdAE	5,62%	2°	7,57%	3°	4,96%	1°
MAPE	219,76%	2°	250,70%	3°	209,24%	1°
MdAPE	57,03%	2°	69,37%	3°	53,76%	1°

Assim, podemos afirmar que a combinação de dados CI aumenta a precisão das previsões do ROA na amostra e obtém um número de previsões mais precisas superior às que utilizaram dados da empresa.

Decompondo o processo de previsão do ROA e analisando as previsões das variáveis e dos indicadores que o compõe, não encontramos muitas diferenças face aos resultados das medidas de precisão anteriormente obtidos. Isto deve-se ao facto de o VN ter sido calculado com recurso a dados setoriais, tornando as previsões do VN iguais em ambos os cenários.

No que diz respeito às outras três variáveis, apesar de serem calculadas da mesma forma que no cenário anterior, as previsões do VN, que faz parte da fórmula da MB e do RO, são diferentes do VN previsto com dados da empresa, porém este facto vem alterar os resultados das previsões para 2009 apenas do indicador GRA, todas as outras previsões são iguais às previsões com dados da empresa.

Como se pode constatar pelos resultados da Tabela 5.2-10, houve uma perda de precisão na previsão do indicador GRA com recurso aos dados combinados, contudo não foi uma

¹⁴ P: Posição

perda suficiente para que a precisão das previsões fosse inferior à precisão das previsões com dados da empresa.

Tabela 5.2-10

Medidas de precisão das previsões do GRA para o total da amostra (E e CI)

Medidas de precisão	E	CI	Δ^{15}	A
MSE	935,48%	771,60%	16,99%	CI
RMSE	305,86%	277,77%	8,16%	CI
MAE	149,60%	131,23%	32,02%	CI
MdAE	66,87%	58,80%	21,97%	CI
MAPE	43,40%	37,93%	27,32%	CI
MdAPE	27,66%	23,28%	28,38%	CI

Resultados do teste de robustez da combinação de dados C2

Conforme a nossa expectativa, houve de facto um aumento na precisão das previsões com recurso aos dados combinados C2 face à precisão das previsões com recurso exclusivo a dados da empresa. A Tabela 5.2-11 apresenta o número de empresas cujas previsões foram mais precisas com um dos dois conjuntos de dados e a Tabela 5.2-12 apresenta os valores das medidas de precisão para cada conjunto.

Tabela 5.2-11

Número de empresas com previsão do ROA mais precisa por conjunto de dados (E e C2)

Conjunto de dados	Nº de Empresas	Percentagem na amostra
E	152	52,23%
C2	139	47,77%
Total da amostra	291	100,00%

Tabela 5.2-12

Medidas de precisão das previsões do ROA para o total da amostra (E e C2)

Medidas de precisão	E	C2	Avaliação
MSE	2,71%	1,67%	C2
RMSE	16,47%	12,91%	C2
MAE	9,45%	8,82%	C2
MdAE	5,62%	6,11%	E
MAPE	219,76%	224,61%	E
MdAPE	57,03%	58,53%	E

¹⁵ Variação dos resultados das medidas de precisão das previsões do GRA face aos resultados obtidos com dados do setor.

Como podemos constatar, houve um ganho significativo na precisão das previsões que utilizaram os dados combinados C2. A amplitude do erro não só é inferior à amplitude do erro com dados da empresa como é também inferior à amplitude do erro com dados do setor. Na Tabela 5.2-13 apresentamos a comparação dos valores das medidas de precisão para os quatro conjuntos de dados estudados.

Tabela 5.2-13

Comparação das medidas de precisão das previsões do ROA com recurso aos conjuntos de dados E, S, CI e C2

Medidas de precisão	E	P	S	P	CI	P	C2	P
MSE	2,71%	4°	2,26%	2°	2,64%	3°	1,67%	1°
RMSE	16,47%	4°	15,04%	2°	16,24%	3°	12,91%	1°
MAE	9,45%	3°	10,60%	4°	9,12%	2°	8,82%	1°
MdAE	5,62%	2°	7,57%	4°	4,96%	1°	6,11%	3°
MAPE	219,76%	2°	250,70%	4°	209,24%	1°	224,61%	3°
MdAPE	57,03%	2°	69,37%	4°	53,76%	1°	58,53%	3°

Conforme se pode constatar, quer no conjunto de dados CI como no C2, a amplitude do erro e o peso relativo do erro na observação, nas previsões do ROA, são inferiores aos outros conjuntos de dados utilizados.

Todas as medidas de precisão apresentam valores inferiores para as previsões que recorrem à combinação de dados. Assim, podemos afirmar que a combinação de dados produz previsões mais precisas do que as previsões que recorrem a dados da empresa e do setor isoladamente, pelo que, de acordo com os resultados obtidos, não rejeitamos *H2*.

Estes resultados comprovam a nossa expectativa inicial, uma vez que, a combinação de previsões obtidas via vários métodos produz previsões mais precisas do que cada uma das previsões que a compõe (Armstrong, 2008). Assim, os resultados obtidos na amostra sugerem que a combinação de dados da empresa com dados do setor obtém, em média, previsões mais precisas do que as obtidas com recurso exclusivo a qualquer um dos conjuntos de dados que compõe as previsões combinadas.

Decompondo o processo de previsão do ROA conforme fizemos anteriormente, constatamos que as melhorias são significativas quer para a previsão do VN quer para a previsão dos quatro indicadores.

No que diz respeito à previsão do VN, esta já era mais precisa com recurso a dados setoriais, porém, com recurso a dados combinados a precisão melhorou. Na Tabela 5.2-14 podemos observar que o número de empresas cuja previsão do VN foi mais precisa diminuiu com recurso a dados da própria empresa.

Tabela 5.2-14

Número de empresas com previsão do VN mais precisa por conjunto de dados (E e C2)

Conjunto de dados	Nº de Empresas	Percentagem na amostra
E	89	30,58%
C2	202	69,42%
Total da amostra	291	100,00%

Confrontando estes resultados com os obtidos com recurso a dados setoriais, o número de empresas cuja previsão do VN foi mais precisa com recurso a dados da empresa diminuiu de 100 para 89 empresas, ou seja, para menos de um terço da amostra.

Desta forma, seria expectável que as medidas de precisão das previsões tivessem melhorado com recurso a dados combinados C2, porém, isso não acontece. Conforme podemos observar pelos resultados das medidas de precisão na Tabela 5.2-15, apesar das previsões do VN com dados combinados serem mais precisas do que com dados da própria empresa, não são mais precisas do que as previsões com recurso a dados setoriais.

Tabela 5.2-15

Comparação das medidas de precisão das previsões do VN com recurso aos conjuntos de dados E, S e C2

Medidas de precisão	E	P	S	P	C2	P
MSE	5.571.948,31	3º	4.372.150,49	1º	4.778.100,30	2º
RMSE	2.360,50	3º	2.090,97	1º	2.185,89	2º
MAE	948,94	3º	761,03	1º	826,72	2º
MdAE	383,35	3º	276,56	1º	306,03	2º
MAPE	23,67%	3º	18,27%	1º	20,15%	2º
MdAPE	14,56%	3º	12,20%	1º	12,70%	2º

Conforme podemos observar pelos resultados da Tabela 5.2-15, as previsões do VN com recurso a dados combinados perderam precisão face às previsões com dados do setor.

A amplitude do erro de precisão e o peso relativo do erro na observação aumentaram com a utilização de dados combinados face aos resultados obtidos via dados setoriais. Contudo, estas previsões continuam a ser mais precisas do que as previsões com recurso a dados da empresa.

Relativamente à previsão dos quatro indicadores, houve, em todos eles, uma melhoria com a utilização de dados combinados. Na Tabela 5.2-16 podemos observar, em termos globais, qual o número de empresas cujas previsões foram mais precisas com recurso a um dos dois conjuntos de dados e também qual a variação face às previsões com dados setoriais.

Tabela 5.2-16

Número de empresas com previsão dos quatro indicadores mais precisa por conjunto de dados (E e C2)

Indicadores	Nº de Empresas		Percentagem na amostra		Δ^{16}	
	E	C2	E	C2	E	C2
TMB	197	94	67,70%	32,30%	-11,26%	36,23%
ECC	180	111	61,86%	38,14%	-14,69%	38,75%
ROVN	181	110	62,20%	37,80%	-12,56%	30,95%
GRA	87	204	29,90%	70,10%	-11,22%	5,70%

Ao analisarmos individualmente os indicadores em termos de medidas de precisão, constatamos que existem semelhanças aos resultados obtidos anteriormente, quando comparámos estas medidas entre dados do setor e dados combinados para a previsão do VN. A Tabela 5.2-17 apresenta os resultados das medidas de precisão com recurso a dados da empresa e dados combinados, fazendo ainda a comparação entre os dados combinados e os setoriais.

¹⁶ Variação do número de empresas, com previsão dos quatro indicadores mais precisa, face aos resultados obtidos na comparação entre dados da empresa e do setor.

Tabela 5.2-17

Medidas de precisão das previsões dos quatro indicadores para o total da amostra (E, S e C2)

Indicadores	Medidas de Precisão	Conjuntos de Dados						
		E	P	S	P	C2	P	Δ^{17}
TMB	MSE	0,49%	1°	1,77%	3°	0,75%	2°	-57,56%
	RMSE	7,00%	1°	13,32%	3°	8,68%	2°	-34,85%
	MAE	4,43%	1°	9,60%	3°	6,15%	2°	-35,90%
	MdAE	3,10%	1°	7,04%	3°	4,64%	2°	-34,12%
	MAPE	8,48%	1°	17,39%	3°	11,25%	2°	-35,30%
	MdAPE	6,11%	1°	14,46%	3°	9,08%	2°	-37,17%
ECC	MSE	0,53%	1°	1,22%	3°	0,71%	2°	-41,32%
	RMSE	7,25%	1°	11,03%	3°	8,45%	2°	-23,39%
	MAE	4,45%	1°	7,17%	3°	5,17%	2°	-27,87%
	MdAE	2,47%	1°	4,40%	3°	2,96%	2°	-32,89%
	MAPE	195,41%	1°	253,67%	3°	213,77%	2°	-15,73%
	MdAPE	35,71%	1°	35,71%	3°	35,71%	2°	0,00%
ROVN	MSE	0,15%	1°	0,35%	3°	0,21%	2°	-39,38%
	RMSE	3,89%	1°	5,90%	3°	4,59%	2°	-22,14%
	MAE	2,38%	1°	3,69%	3°	2,77%	2°	-24,99%
	MdAE	1,29%	1°	2,11%	3°	1,42%	2°	-32,74%
	MAPE	190,48%	2°	199,71%	3°	183,41%	2°	-8,16%
	MdAPE	36,57%	1°	64,22%	3°	44,12%	2°	-31,31%
GRA	MSE	935,48%	3°	659,53%	1°	717,67%	2°	8,81%
	RMSE	305,86%	3°	256,81%	1°	267,89%	2°	4,31%
	MAE	149,60%	3°	99,40%	1°	124,53%	2°	25,29%
	MdAE	66,87%	3°	48,21%	1°	56,80%	2°	17,81%
	MAPE	43,40%	3°	29,79%	1°	36,08%	2°	21,10%
	MdAPE	27,66%	3°	18,13%	1°	22,31%	2°	23,07%

Como podemos constatar pelos resultados apresentados, há dois fenómenos que são verificados:

- 1°. As previsões dos indicadores, cuja precisão com dados setoriais é inferior à precisão com dados da empresa, via utilização de dados combinados melhoraram a precisão das previsões face àquelas obtidas com recurso a dados setoriais.

¹⁷ Variação dos resultados das medidas de precisão entre os resultados obtidos com dados C2 e dados do setor.

2°. A previsão do indicador GRA que já era, substancialmente, mais precisa com recurso a dados setoriais do que com dados da própria empresa, a utilização de dados combinados piorou todas as medidas de precisão face à utilização de dados setoriais.

O mesmo sucedeu com a precisão das previsões do GRA com dados combinados C1 e do VN e dos quatro indicadores com dados combinados C2. Onde a precisão das previsões com dados setoriais é inferior à precisão das previsões com dados da empresa, a utilização de dados combinados melhorou as medidas de precisão. No entanto, no caso da precisão das previsões que já eram mais precisas com recurso a dados setoriais, as medidas de precisão pioraram com a utilização de dados combinados.

Estes resultados reforçam a ideia que o AC e o VN, para as empresas da amostra, convergem para os valores do setor, pelo que a inclusão de dados da empresa no processo de previsão fez com que houvesse uma perda de precisão. Já o RO e a MB parecem não convergir para os valores do setor, uma vez que a inclusão de dados da empresa melhorou a precisão das previsões face àquela obtida via uso exclusivo de dados do setor.

5.3. Resultados por quintis

Na Tabela 5.3-1 está discriminado, por quintil, para a previsão do ROA qual o número de empresas que cada conjunto de dados melhor previu.

Tabela 5.3-1


Número de empresas por quintil com previsões do ROA mais precisas para cada conjunto de dados

Conjunto de dados	1º Quintil	2º Quintil	3º Quintil	4º Quintil	5º Quintil	Total
	Nº de previsões mais precisas	Nº de previsões mais precisas	Nº de previsões mais precisas	Nº de previsões mais precisas	Nº de previsões mais precisas	
E	19	16	15	13	10	73
S	11	14	20	19	26	90
C1	20	17	16	18	14	85
C2	8	11	7	8	9	43
Total	58	58	58	58	59	291

Como se pode constatar pelos resultados da Tabela 5.3-1 e da Figura 5.3-1 e contrariamente às nossas expectativas, à medida que a dimensão da empresa vai diminuindo na amostra, a precisão das previsões com recurso a dados da empresa vai diminuindo e com recurso a dados setoriais vai aumentando. Assim, de acordo com os resultados, rejeitamos $H5$.

Figura 5.3-1

Evolução do número de empresas que cada conjunto de dados melhor previu



Podemos também verificar que a evolução do número de empresas com melhores previsões com dados combinados CI acompanha a evolução dos dados da empresa uma vez que a única diferença entre os dois conjuntos é a previsão do VN. Já o conjunto de dados C2 apresenta uma evolução mais constante, pois resulta da combinação de dados do setor e da empresa.

Para melhor compreendermos estes efeitos vamos detalhar a análise e discutir os resultados por quintil.

Resultados do primeiro quintil

Como podemos constatar e contrariamente às nossas expectativas, os dados da própria empresa produziram previsões do ROA mais precisas relativamente às previsões obtidas via a utilização dos outros três conjuntos de dados para o primeiro quintil. Os resultados da Tabela 5.3-2 mostram que a amplitude do erro de previsão com recurso a dados da empresa é substancialmente inferior à amplitude do erro com recurso a dados setoriais e

combinados. Contudo, o peso relativo do erro na observação é inferior com a utilização de dados combinados C1 do que com a utilização dos restantes conjuntos.

Tabela 5.3-2

Medidas de precisão das previsões do ROA para o primeiro quintil

Medidas de Precisão	E	P	S	P	C1	P	C2	P
MSE	0,74%	1°	8,48%	4°	5,54%	2°	6,38%	3°
RMSE	8,60%	1°	29,11%	4°	23,54%	2°	25,25%	3°
MAE	5,38%	1°	8,48%	4°	5,54%	2°	6,38%	3°
MdAE	3,13%	1°	6,20%	4°	3,97%	2°	4,07%	3°
MAPE	124,36%	1°	228,67%	4°	126,58%	2°	166,90%	3°
MdAPE	45,40%	2°	69,19%	4°	44,60%	1°	47,50%	3°

Na Tabela 5.3-3 são apresentados os resultados das medidas de precisão das previsões do VN com recurso aos três conjuntos de dados utilizados¹⁸.

Tabela 5.3-3

Medidas de precisão das previsões do VN para o primeiro quintil

Medidas de Precisão	E	P	S	P	C2	P
MSE	22.525.278,57	3°	20.262.730,83	1°	21.097.063,22	2°
RMSE	4.746,08	3°	4.501,41	1°	4.593,15	2°
MAE	2.240,46	3°	2.165,90	1°	2.173,01	2°
MdAE	806,19	1°	1.110,49	3°	946,14	2°
MAPE	23,82%	3°	23,26%	2°	22,99%	1°
MdAPE	12,24%	1°	15,86%	3°	13,65%	2°

Como podemos observar e conforme a nossa expectativa, as previsões com recurso a dados da empresa obtiveram uma amplitude do erro superior à dos outros conjuntos de dados. Porém, o peso relativo do erro na observação, captado na medida MdAPE, foi, com dados da empresa, inferior ao obtido com recurso aos outros conjuntos de dados. Já a medida MAPE apresenta uma grande proximidade entre os três conjuntos de dados.

Decompondo a previsão do ROA nos quatro indicadores que o determinam, conforme apresentado na Tabela 5.3-4, constatamos que a combinação de dados C2 produz previsões com menor amplitude de erro e com menor peso relativo do erro na observação do que as previsões com dados setoriais para todos os indicadores exceto no GRA. Desta forma, verificamos o mesmo efeito que ocorreu nos resultados globais.

¹⁸ Para o VN as medidas de precisão dos dados combinados C1 são iguais às obtidas via dados do setor.

Tabela 5.3-4**Medidas de precisão das previsões dos quatro indicadores para o primeiro quintil**

Indicadores	Medidas de Precisão	Conjuntos de Dados							
		E	P	S	P	C1 ¹⁹	P	C2	P
TMB	MSE	0,35%	1º	1,06%	3º	n.a.	-	0,50%	2º
	RMSE	5,89%	1º	10,31%	3º	n.a.	-	7,05%	2º
	MAE	4,04%	1º	8,45%	3º	n.a.	-	5,51%	2º
	MdAE	2,99%	1º	7,23%	3º	n.a.	-	5,12%	2º
	MAPE	7,97%	1º	17,13%	3º	n.a.	-	10,92%	2º
	MdAPE	6,31%	1º	14,21%	3º	n.a.	-	10,14%	2º
ECC	MSE	0,92%	1º	2,11%	3º	n.a.	-	1,29%	2º
	RMSE	9,59%	1º	14,53%	3º	n.a.	-	11,35%	2º
	MAE	5,54%	1º	9,07%	3º	n.a.	-	6,85%	2º
	MdAE	2,41%	1º	4,91%	3º	n.a.	-	3,67%	2º
	MAPE	98,24%	1º	174,25%	3º	n.a.	-	131,24%	2º
	MdAPE	32,38%	1º	67,98%	3º	n.a.	-	40,40%	2º
ROVN	MSE	0,20%	1º	0,52%	3º	n.a.	-	0,31%	2º
	RMSE	4,50%	1º	7,23%	3º	n.a.	-	5,56%	2º
	MAE	2,82%	1º	4,54%	3º	n.a.	-	3,49%	2º
	MdAE	1,40%	1º	2,17%	3º	n.a.	-	1,59%	2º
	MAPE	102,82%	1º	171,16%	3º	n.a.	-	131,81%	2º
	MdAPE	36,57%	1º	66,87%	3º	n.a.	-	47,82%	2º
GRA	MSE	58,55%	4º	39,94%	1º	53,13%	3º	44,28%	2º
	RMSE	76,52%	4º	63,20%	1º	72,89%	3º	66,54%	2º
	MAE	51,14%	4º	41,55%	1º	49,87%	3º	43,30%	2º
	MdAE	25,17%	3º	23,07%	1º	27,00%	4º	24,47%	2º
	MAPE	25,38%	4º	21,01%	1º	25,13%	3º	21,35%	2º
	MdAPE	20,29%	4º	13,81%	1º	17,41%	3º	15,16%	2º

Resultados do segundo quintil

Os resultados neste quintil sugerem que, à medida que a dimensão da empresa vai diminuindo na amostra, a precisão das previsões do ROA com dados da empresa vai igualmente diminuindo. Os resultados da Tabela 5.3-5 assim o indicam. Relativamente aos resultados do primeiro quintil, as medidas de precisão das previsões com recurso a dados

¹⁹ As medidas de precisão dos dados combinados CI são iguais às obtidas via dados da empresa para a TMB, o ECC e o ROVN.

da empresa pioraram, em média, 18,86% e a maior melhoria média das medidas de precisão foi de 24,37% correspondente ao conjunto de dados combinados C2.

A amplitude do erro é agora inferior com dados combinados CI do que com dados da empresa. Contudo, a amplitude do erro continua a ser superior com dados setoriais do que com dados da empresa, apesar de essa diferença já não ser tão expressiva, demonstrando um aumento de precisão das previsões com dados setoriais à medida que a dimensão e maturidade da empresa vão diminuindo.

O peso relativo do erro na observação é agora menor nas previsões com recurso a dados combinados C2, do que nas previsões com recurso aos outros conjuntos, evidenciando a melhoria significativa na precisão das previsões que este conjunto de dados obteve neste quintil.

Tabela 5.3-5

Medidas de precisão das previsões do ROA para o segundo quintil

Medidas de Precisão	E	Δ^{20}	P	S	Δ	P	CI	Δ	P	C2	Δ	P
MSE	0,84%	14,09%	2°	1,56%	-81,54%	4°	0,82%	-85,19%	1°	0,91%	-85,74%	3°
RMSE	9,18%	6,81%	2°	12,51%	-57,03%	4°	9,06%	-61,52%	1°	9,54%	-62,23%	3°
MAE	6,64%	23,27%	2°	9,48%	11,84%	4°	6,52%	17,60%	1°	6,88%	7,83%	3°
MdAE	4,82%	54,02%	2°	7,27%	17,22%	4°	4,47%	12,54%	1°	5,42%	33,34%	3°
MAPE	134,38%	8,06%	2°	147,70%	-35,41%	4°	135,08%	6,72%	3°	116,82%	-30,00%	1°
MdAPE	48,54%	6,92%	3°	74,62%	7,84%	4°	45,86%	2,83%	2°	43,02%	-9,43%	1°

De acordo com os resultados da Tabela 5.3-6, houve uma melhoria significativa na precisão das previsões do VN com recurso a dados da empresa. Contudo, essa melhoria foi acompanhada por uma melhoria, também ela significativa, da precisão das previsões com recurso aos outros conjuntos de dados. Estes resultados sugerem uma maior capacidade preditiva dos dados setoriais na previsão do VN para empresas de dimensão média/alta.

²⁰ Variação dos resultados das medidas de precisão face aos resultados do quintil anterior.

Tabela 5.3-6

Medidas de precisão das previsões do VN para o segundo quintil

Medidas de Precisão	E	Δ	P	S	Δ	P	C 2	Δ	P
MSE	1.392.171,39	-93,82%	3º	688.304,67	-96,60%	1º	921.338,36	-95,63%	2º
RMSE	1.179,90	-75,14%	3º	829,64	-81,57%	1º	959,86	-79,10%	2º
MAE	829,48	-62,98%	3º	601,29	-72,24%	1º	693,10	-68,10%	2º
MdAE	468,75	-41,86%	3º	405,32	-63,50%	2º	402,17	-57,49%	1º
MAPE	20,61%	-13,45%	3º	15,38%	-33,87%	1º	17,51%	-23,83%	2º
MdAPE	11,44%	-6,51%	2º	11,26%	-29,02%	1º	12,23%	-10,37%	3º

Relativamente aos quatro indicadores que compõem o ROA, os resultados das medidas de precisão mantêm-se inalterados, conforme ilustrado na Tabela 5.3-7, com os dados da empresa a obterem previsões mais precisas para os indicadores TMB, ECC e ROVN e os dados do setor a obterem previsões mais precisas para o indicador GRA.

Tabela 5.3-7

Medidas de precisão das previsões dos quatro indicadores para o segundo quintil

Indicadores	Medidas de Precisão	Conjuntos de Dados											
		E	Δ	P	S	Δ	P	C1	Δ	P	C2	Δ	P
TMB	MSE	0,24%	-30,43%	1º	0,94%	-11,41%	3º	n.a.	-	-	0,39%	-21,20%	2º
	RMSE	4,92%	-16,59%	1º	9,71%	-5,88%	3º	n.a.	-	-	6,26%	-11,23%	2º
	MAE	3,81%	-5,53%	1º	7,39%	-12,51%	3º	n.a.	-	-	5,12%	-7,11%	2º
	MdAE	3,24%	8,42%	1º	6,40%	-11,55%	3º	n.a.	-	-	3,82%	-25,54%	2º
	MAPE	7,49%	-5,93%	1º	14,81%	-13,55%	3º	n.a.	-	-	10,14%	-7,12%	2º
	MdAPE	5,94%	-5,93%	1º	12,68%	-10,79%	3º	n.a.	-	-	8,17%	-19,48%	2º
ECC	MSE	0,91%	-1,42%	1º	2,01%	-4,79%	3º	n.a.	-	-	1,29%	0,05%	2º
	RMSE	9,52%	-0,71%	1º	14,18%	-2,42%	3º	n.a.	-	-	11,35%	0,02%	2º
	MAE	5,52%	-0,35%	1º	8,79%	-3,10%	3º	n.a.	-	-	6,54%	-4,59%	2º
	MdAE	2,97%	23,36%	1º	4,33%	-11,80%	3º	n.a.	-	-	3,28%	-10,44%	2º
	MAPE	114,41%	16,46%	2º	139,71%	-19,82%	3º	n.a.	-	-	106,04%	-19,20%	1º
	MdAPE	35,97%	11,11%	1º	68,23%	0,36%	3º	n.a.	-	-	44,11%	9,18%	2º
ROVN	MSE	0,28%	36,84%	1º	0,53%	1,36%	3º	n.a.	-	-	0,36%	17,27%	2º
	RMSE	5,26%	16,98%	1º	7,28%	0,68%	3º	n.a.	-	-	6,02%	8,29%	2º
	MAE	2,91%	3,20%	1º	4,38%	-3,64%	3º	n.a.	-	-	3,28%	-5,91%	2º
	MdAE	1,30%	-7,48%	1º	2,27%	4,53%	3º	n.a.	-	-	1,44%	-9,60%	2º
	MAPE	113,99%	10,86%	2º	124,86%	-27,05%	3º	n.a.	-	-	97,66%	-25,91%	1º
	MdAPE	34,31%	-6,18%	1º	69,49%	3,92%	3º	n.a.	-	-	46,78%	-2,18%	2º
GRA	MSE	113,63%	94,07%	4º	62,15%	55,63%	1º	96,41%	81,46%	3º	81,90%	84,97%	2º

Indicadores	Medidas de Precisão	Conjuntos de Dados											
		E	Δ	P	S	Δ	P	C1	Δ	P	C2	Δ	P
	RMSE	106,60%	39,31%	4º	78,84%	24,75%	1º	98,19%	34,71%	3º	90,50%	36,00%	2º
	MAE	84,17%	64,59%	4º	56,86%	36,83%	1º	74,56%	49,49%	3º	68,89%	59,11%	2º
	MdAE	63,83%	153,57%	4º	39,74%	72,27%	1º	55,65%	106,10%	3º	48,28%	97,28%	2º
	MAPE	38,03%	49,84%	4º	26,13%	24,35%	1º	32,85%	30,72%	3º	31,42%	47,13%	2º
	MdAPE	26,80%	32,08%	4º	18,36%	32,96%	1º	22,68%	30,31%	3º	22,00%	45,17%	2º

Resultados do terceiro quintil

Contrariamente à nossa expectativa, as previsões do ROA menos precisas foram as que utilizaram os dados da empresa. Os resultados são os apresentados na Tabela 5.3-8.

Tabela 5.3-8

Medidas de precisão das previsões do ROA para o terceiro quintil

Medidas de Precisão	E	Δ	P	S	Δ	P	C1	Δ	P	C2	Δ	P
MSE	3,35%	296,71%	4º	1,46%	-6,90%	2º	2,75%	234,85%	3º	1,21%	33,34%	1º
RMSE	18,29%	99,18%	4º	12,07%	-3,51%	2º	16,58%	82,99%	3º	11,01%	15,48%	1º
MAE	9,08%	36,75%	4º	8,44%	-11,01%	3º	7,94%	21,85%	2º	7,56%	10,00%	1º
MdAE	4,63%	-3,84%	2º	5,66%	-22,20%	4º	4,18%	-6,37%	1º	4,92%	-9,25%	3º
MAPE	209,05%	55,56%	2º	274,53%	85,87%	4º	178,59%	32,20%	1º	233,12%	99,55%	3º
MdAPE	58,97%	21,48%	2º	81,02%	8,58%	4º	56,50%	23,20%	1º	65,24%	51,65%	3º

A amplitude do erro das previsões com dados da empresa é bastante superior à amplitude do erro das previsões com dados combinados segunda fase e dados setoriais.

Os dados setoriais obtiveram uma melhoria significativa relativamente à amplitude do erro, contudo, os dados combinados C2, apesar de terem aumentado a amplitude média do erro de previsão face aos resultados do segundo quintil, continuam a ter uma amplitude do erro de previsão menor do que aquela obtida via dados setoriais.

O peso relativo do erro de previsão na observação aumentou para os quatro conjuntos de dados.

Os resultados das medidas de precisão, expostos na Tabela 5.3-9, para o VN sugerem que à medida que as empresas vão diminuindo em termos de dimensão, os dados setoriais vão diminuindo a amplitude do erro de previsão. Face ao quintil anterior, houve um aumento do peso relativo do erro na observação das previsões obtidas via dados setoriais, algo que também sucedeu para os outros conjuntos de dados.

Tabela 5.3-9

Medidas de precisão das previsões do VN para o terceiro quintil

Medidas de Precisão	VN 3° Quintil								
	E	Δ	P	S	Δ	P	C2	Δ	P
MSE	3.280.969,70	135,67%	3°	649.494,35	-5,64%	1°	1.465.583,50	59,07%	2°
RMSE	1.811,34	53,52%	3°	805,91	-2,86%	1°	1.210,61	26,12%	2°
MAE	935,35	12,76%	3°	538,52	-10,44%	1°	686,53	-0,95%	2°
MdAE	412,24	-12,06%	3°	313,23	-22,72%	1°	328,13	-18,41%	2°
MAPE	27,20%	31,93%	3°	20,17%	31,09%	1°	22,55%	28,80%	2°
MdAPE	16,83%	47,10%	2°	11,45%	1,68%	1°	11,87%	-2,95%	3°

Relativamente aos quatro indicadores, neste quintil, houve uma maior aproximação dos resultados das medidas de precisão obtidos via os quatro conjuntos de dados utilizados, conforme se pode constatar pelos resultados da Tabela 5.3-10.

Tabela 5.3-10

Medidas de precisão das previsões dos quatro indicadores para o terceiro quintil

Indicadores	Medidas de Precisão	Conjuntos de Dados											
		E	Δ	P	S	Δ	P	CI	Δ	P	C2	Δ	P
TYMB	MSE	0,40%	64,47%	1°	0,93%	-1,47%	3°	n.a.	-	-	0,43%	9,82%	2°
	RMSE	6,31%	28,25%	1°	9,63%	-0,74%	3°	n.a.	-	-	6,56%	4,80%	2°
	MAE	4,54%	19,12%	1°	7,45%	0,76%	3°	n.a.	-	-	4,68%	-8,56%	2°
	MdAE	3,67%	13,32%	2°	5,67%	-11,30%	3°	n.a.	-	-	3,45%	-9,53%	1°
	MAPE	9,48%	26,50%	2°	14,19%	-4,14%	3°	n.a.	-	-	9,10%	-10,26%	1°
	MdAPE	7,10%	19,59%	1°	12,39%	-2,30%	3°	n.a.	-	-	7,31%	-10,52%	2°
ECC	MSE	0,23%	-75,02%	1°	0,46%	-77,36%	3°	n.a.	-	-	0,25%	-80,89%	2°
	RMSE	4,76%	-50,02%	1°	6,75%	-52,42%	3°	n.a.	-	-	4,96%	-56,28%	2°
	MAE	3,22%	-41,60%	1°	5,05%	-42,55%	3°	n.a.	-	-	3,54%	-45,92%	2°
	MdAE	1,87%	-36,93%	1°	4,22%	-2,61%	3°	n.a.	-	-	2,42%	-26,44%	2°
	MAPE	120,87%	5,64%	1°	231,79%	65,91%	3°	n.a.	-	-	159,24%	50,17%	2°
	MdAPE	40,10%	11,48%	1°	62,55%	-8,33%	3°	n.a.	-	-	46,72%	5,92%	2°
ROVN	MSE	0,06%	-80,01%	1°	0,12%	-77,62%	3°	n.a.	-	-	0,07%	-81,51%	2°
	RMSE	2,35%	-55,29%	1°	3,44%	-52,69%	3°	n.a.	-	-	2,59%	-57,00%	2°
	MAE	1,53%	-47,40%	1°	2,51%	-42,58%	3°	n.a.	-	-	1,82%	-44,50%	2°
	MdAE	0,84%	-34,98%	1°	1,83%	-19,17%	3°	n.a.	-	-	1,18%	-18,20%	2°
	MAPE	111,48%	-2,21%	1°	210,67%	68,73%	3°	n.a.	-	-	149,91%	53,51%	2°
	MdAPE	36,29%	5,77%	1°	68,18%	-1,89%	3°	n.a.	-	-	41,88%	-10,48%	2°
GRA	MSE	588,87%	418,22%	4°	201,09%	223,53%	1°	277,91%	188,24%	2°	334,34%	308,25%	3°
	RMSE	242,67%	127,65%	4°	141,81%	79,87%	1°	166,71%	69,78%	2°	182,85%	102,05%	3°

Indicadores	Medidas de Precisão	Conjuntos de Dados											
		E	Δ	P	S	Δ	P	CI	Δ	P	C2	Δ	P
	MAE	142,07%	68,80%	4°	87,78%	54,39%	1°	98,63%	32,29%	2°	113,60%	64,89%	3°
	MdAE	76,36%	19,63%	4°	49,49%	24,56%	1°	62,36%	12,05%	2°	70,67%	46,38%	3°
	MAPE	48,84%	28,44%	4°	29,68%	13,61%	1°	38,93%	18,49%	3°	38,47%	22,43%	3°
	MdAPE	33,47%	24,89%	4°	17,22%	-6,23%	1°	21,13%	-6,83%	2°	25,02%	13,72%	3°

Globalmente, os resultados mantêm-se inalterados com as previsões dos indicadores TMB, ECC e ROVN a serem mais precisas com dados da empresa e as previsões do GRA a serem mais precisas com a utilização de dados setoriais.

Resultados do quarto quintil

De acordo com os resultados expostos na Tabela 5.3-11, os dados combinados primeira e segunda fase são aqueles que obtiveram uma menor amplitude do erro de previsão e um menor peso relativo do erro de previsão na observação.

Importa ainda realçar que o conjunto de dados que obteve a maior melhoria face aos resultados do quintil anterior foi o conjunto de dados da empresa, com uma redução média nos resultados das medidas de precisão de 13,29%.

Tabela 5.3-11

Medidas de precisão das previsões do ROA para o quarto quintil

Medidas de Precisão	E	Δ	P	S	Δ	P	CI	Δ	P	C2	Δ	P
MSE	1,42%	-57,55%	3°	1,29%	-11,63%	2°	1,45%	-47,06%	4°	1,05%	-13,23%	1°
RMSE	11,92%	-34,84%	3°	11,35%	-6,00%	2°	12,06%	-27,24%	4°	10,26%	-6,85%	1°
MAE	8,28%	-8,81%	3°	9,27%	9,90%	4°	7,89%	-0,61%	1°	8,21%	8,49%	2°
MdAE	6,42%	38,60%	2°	8,69%	53,55%	4°	6,42%	53,31%	1°	7,44%	51,18%	3°
MAPE	153,50%	-26,57%	2°	254,07%	-7,45%	4°	144,42%	-19,13%	1°	192,78%	-17,31%	3°
MdAPE	64,53%	9,43%	3°	77,11%	-4,82%	4°	54,60%	-3,36%	1°	60,49%	-7,28%	2°

Relativamente à previsão do VN, as previsões obtidas via a utilização de dados setoriais obtiveram a menor amplitude de erro e o menor peso relativo do erro na observação, conforme apresentado na Tabela 5.3-12. Genericamente, a precisão das previsões melhorou para os três conjuntos de dados utilizados.

Tabela 5.3-12

Medidas de precisão das previsões do VN para o quarto quintil

Medidas de Precisão	VN 4º Quintil								
	E	Δ	P	S	Δ	P	C 2ª	Δ	P
MSE	349.674,74	-89,34%	3º	174.487,23	-73,13%	1º	232.901,08	-84,11%	2º
RMSE	591,33	-67,35%	3º	417,72	-48,17%	1º	482,60	-60,14%	2º
MAE	399,32	-57,31%	3º	274,95	-48,94%	1º	316,41	-53,91%	2º
MdAE	299,89	-27,25%	3º	180,82	-42,27%	1º	197,60	-39,78%	2º
MAPE	22,95%	-15,63%	3º	16,31%	-19,11%	1º	18,82%	-16,56%	2º
MdAPE	17,25%	2,51%	3º	12,15%	6,11%	1º	14,56%	22,62%	2º

A precisão das previsões dos quatro indicadores, genericamente, piorou face aos resultados obtidos no quintil anterior. Conforme se pode constatar pela Tabela 5.3-13, o único conjunto de dados que obteve ganhos de precisão significativos foi o conjunto de dados da empresa que se manteve como o melhor conjunto para prever a TMB, o ECC e o ROVN. Apesar de uma maior aproximação, na precisão das previsões do indicador GRA, às previsões obtidas com dados setoriais, os dados da empresa continuam, em termos de precisão das previsões, aquém dos resultados obtidos com dados setoriais.

Tabela 5.3-13

Medidas de precisão das previsões dos quatro indicadores para o quarto quintil

Indicadores	Medidas de Precisão	Conjuntos de Dados											
		E	Δ	P	S	Δ	P	C1	Δ	P	C2	Δ	P
TMB	MSE	0,85%	114,72%	1º	2,28%	145,21%	3º	n.a.	-	-	1,16%	170,29%	2º
	RMSE	9,24%	46,53%	1º	15,09%	56,59%	3º	n.a.	-	-	10,79%	64,40%	2º
	MAE	4,61%	1,58%	1º	10,81%	45,24%	3º	n.a.	-	-	7,04%	50,54%	2º
	MdAE	2,42%	-34,01%	1º	7,13%	25,70%	3º	n.a.	-	-	4,34%	25,71%	2º
	MAPE	7,74%	-18,38%	1º	17,69%	24,61%	3º	n.a.	-	-	11,52%	26,66%	2º
	MdAPE	4,78%	-32,65%	1º	14,76%	19,18%	3º	n.a.	-	-	9,14%	25,10%	2º
ECC	MSE	0,22%	-2,37%	1º	0,63%	38,86%	3º	n.a.	-	-	0,30%	20,72%	2º
	RMSE	4,70%	-1,19%	1º	7,95%	17,84%	3º	n.a.	-	-	5,45%	9,87%	2º
	MAE	3,48%	7,88%	1º	5,88%	16,48%	3º	n.a.	-	-	3,95%	11,84%	2º
	MdAE	2,04%	8,67%	1º	4,16%	-1,36%	3º	n.a.	-	-	2,35%	-2,75%	2º
	MAPE	134,89%	11,60%	1º	258,95%	11,72%	3º	n.a.	-	-	180,28%	13,21%	2º
	MdAPE	32,75%	-18,34%	1º	65,87%	5,32%	3º	n.a.	-	-	39,46%	-15,54%	2º
ROVN	MSE	0,07%	32,25%	1º	0,21%	74,89%	3º	n.a.	-	-	0,11%	64,44%	2º
	RMSE	2,71%	15,00%	1º	4,56%	32,25%	3º	n.a.	-	-	3,32%	28,24%	2º
	MAE	1,94%	26,88%	1º	3,16%	25,74%	3º	n.a.	-	-	2,28%	25,18%	2º

Indicadores	Medidas de Precisão	Conjuntos de Dados											
		E	Δ	P	S	Δ	P	C1	Δ	P	C2	Δ	P
	MdAE	1,12%	32,28%	1º	2,13%	16,45%	3º	n.a.	-	-	1,38%	16,97%	2º
	MAPE	129,30%	15,98%	1º	214,95%	2,03%	3º	n.a.	-	-	161,43%	7,68%	2º
	MdAPE	34,55%	-4,81%	1º	58,26%	-14,55%	3º	n.a.	-	-	40,97%	-2,17%	2º
GRA	MSE	420,21%	-28,64%	4º	289,34%	43,89%	1º	370,15%	33,19%	2º	416,43%	24,55%	3º
	RMSE	204,99%	-15,53%	4º	170,10%	19,95%	1º	192,39%	15,41%	2º	204,07%	11,60%	3º
	MAE	141,01%	-0,75%	4º	95,20%	8,45%	1º	123,52%	25,23%	2º	123,75%	8,94%	3º
	MdAE	84,35%	10,48%	4º	55,65%	12,44%	1º	69,66%	11,70%	2º	70,09%	-0,82%	3º
	MAPE	40,79%	-16,48%	4º	29,18%	-1,70%	1º	34,86%	-10,45%	2º	36,06%	-6,26%	3º
	MdAPE	28,40%	-15,14%	4º	19,05%	10,60%	1º	22,80%	7,89%	3º	21,02%	-16,00%	2º

Resultados do quinto quintil

Contrariamente à nossa expectativa inicial, os resultados deste quintil não são favoráveis à utilização de dados da própria empresa para realizar previsões do ROA.

As previsões do ROA, cuja amplitude do erro foi menor, foram as que utilizaram o conjunto de dados combinados C2 e as que obtiveram um menor peso relativo do erro de previsão na observação foram as que utilizaram dados setoriais.

Os resultados da Tabela 5.3-14 evidenciam ainda uma relativa proximidade entre as medidas de precisão dos quatro conjuntos de dados.

Tabela 5.3-14

Medidas de precisão das previsões do ROA para o quinto quintil

Medidas de Precisão	E	Δ	P	S	Δ	P	C1	Δ	P	C2	Δ	P
MSE	7,25%	410,57%	3º	5,48%	325,80%	2º	7,41%	409,55%	4º	4,17%	296,07%	1º
RMSE	26,93%	125,96%	3º	23,41%	106,35%	2º	27,23%	125,73%	4º	20,42%	99,01%	1º
MAE	17,88%	116,02%	4º	17,30%	86,63%	2º	17,70%	124,28%	3º	15,03%	83,16%	1º
MdAE	13,09%	103,99%	4º	12,05%	38,70%	2º	12,40%	93,32%	3º	11,70%	57,35%	1º
MAPE	479,96%	212,67%	4º	350,71%	38,04%	1º	463,67%	221,05%	3º	415,61%	115,59%	2º
MdAPE	64,11%	-0,64%	4º	59,10%	-23,36%	1º	60,22%	10,29%	2º	60,55%	0,09%	3º

Com respeito à previsão do VN, a utilização de dados setoriais, obteve, neste quintil, a menor amplitude de erro medida ao longo de toda a amostra. De acordo com os resultados da Tabela 5.3-15, o peso relativo do erro de previsão na observação foi, também, dos mais baixos alcançados em toda a amostra. Estes resultados sugerem uma

forte capacidade preditiva dos dados do setor para a previsão do VN em empresas de menor dimensão.

Tabela 5.3-15

Medidas de precisão das previsões do VN para o quinto quintil

Medidas de Precisão	VN 5º Quintil								
	E	Δ	P	S	Δ	P	C2	Δ	P
MSE	403.006,00	15,25%	3º	158.833,93	-8,97%	1º	243.846,19	4,70%	2º
RMSE	634,83	7,36%	3º	398,54	-4,59%	1º	493,81	2,32%	2º
MAE	347,42	-13,00%	3º	231,31	-15,87%	1º	267,79	-15,37%	2º
MdAE	182,94	-39,00%	3º	126,45	-30,07%	1º	167,49	-15,24%	2º
MAPE	23,95%	4,39%	3º	16,37%	0,39%	1º	18,98%	0,88%	2º
MdAPE	16,81%	-2,53%	3º	12,27%	1,03%	1º	12,90%	-11,35%	2º

Relativamente à previsão dos quatro indicadores, neste quintil, a perda de precisão das previsões deu-se para todos os conjuntos de dados, conforme ilustrado na Tabela 5.3-16. Contudo, a perda mais acentuada verificou-se na previsão do indicador GRA, em que, a amplitude do erro de previsão foi significativamente elevada para os quatro conjuntos de dados utilizados. De realçar que, em média, o conjunto de dados que menos piorou a precisão das suas previsões foi o conjunto de dados da empresa, que aumentou 273,53% os resultados obtidos das medidas MSE, RMSE, MAE e MdAE e o conjunto que piorou mais foi o conjunto de dados setoriais, que aumentou os resultados obtidos das mesmas medidas de precisão, em média, 308,23%.

Tabela 5.3-16

Medidas de precisão das previsões dos quatro indicadores para o quinto quintil

Indicadores	Medidas de Precisão	Conjuntos de Dados											
		E	Δ	P	S	Δ	P	CI	Δ	P	C2	Δ	P
TMB	MSE	0,62%	-27,94%	1º	3,68%	61,55%	3º	n.a.	-	-	1,29%	10,59%	2º
	RMSE	7,84%	-15,11%	1º	19,18%	27,10%	3º	n.a.	-	-	11,34%	5,16%	2º
	MAE	5,14%	11,30%	1º	13,89%	28,45%	3º	n.a.	-	-	8,38%	18,96%	2º
	MdAE	3,72%	53,70%	1º	5,83%	-18,28%	3º	n.a.	-	-	5,30%	22,06%	2º
	MAPE	9,63%	24,45%	1º	22,99%	29,97%	3º	n.a.	-	-	14,42%	25,17%	2º
	MdAPE	6,80%	42,07%	1º	21,75%	47,35%	3º	n.a.	-	-	12,22%	33,68%	2º
ECC	MSE	0,36%	64,59%	1º	0,90%	42,01%	3º	n.a.	-	-	0,46%	55,38%	2º
	RMSE	6,03%	28,29%	1º	9,47%	19,17%	3º	n.a.	-	-	6,80%	24,65%	2º
	MAE	4,56%	31,08%	1º	7,19%	22,28%	3º	n.a.	-	-	5,06%	28,06%	2º
	MdAE	3,37%	65,49%	2º	5,46%	31,18%	3º	n.a.	-	-	2,98%	26,82%	1º

	MAPE	511,66%	279,32%	2°	467,95%	80,71%	3°	n.a.	-	-	495,60%	174,90%	1°
	MdAPE	37,66%	15,00%	1°	61,82%	-6,16%	3°	n.a.	-	-	47,28%	19,82%	2°
ROVN	MSE	0,15%	106,54%	1°	0,37%	76,90%	3°	n.a.	-	-	0,21%	89,76%	2°
	RMSE	3,89%	43,71%	1°	6,06%	33,00%	3°	n.a.	-	-	4,58%	37,75%	2°
	MAE	2,71%	39,58%	1°	3,92%	24,02%	3°	n.a.	-	-	3,02%	32,41%	2°
	MdAE	1,85%	66,02%	2°	2,46%	15,10%	3°	n.a.	-	-	1,72%	24,84%	1°
	MAPE	497,46%	284,75%	2°	279,98%	30,25%	3°	n.a.	-	-	378,93%	134,74%	1°
	MdAPE	39,62%	14,68%	1°	61,40%	5,40%	3°	n.a.	-	-	43,95%	7,29%	2°
GRA	MSE	3510,18%	735,34%	4°	2700,27%	833,24%	1°	3070,55%	729,55%	3°	2717,30%	552,52%	2°
	RMSE	592,47%	189,02%	4°	519,64%	205,49%	1°	554,13%	188,02%	3°	521,28%	155,45%	2°
	MAE	330,27%	134,22%	4°	212,03%	122,72%	1°	309,56%	150,63%	3°	271,94%	119,74%	2°
	MdAE	114,34%	35,54%	4°	95,43%	71,49%	1°	112,72%	61,83%	2°	125,98%	79,75%	3°
	MAPE	64,18%	57,34%	4°	42,00%	43,93%	1°	57,91%	66,14%	3°	52,78%	46,38%	2°
	MdAPE	36,56%	28,73%	4°	23,55%	23,67%	1°	33,49%	46,88%	3°	28,74%	36,75%	2°

5.4. Resultados da previsão financeira com recurso a dados subsetoriais

Utilizando a divisão por quintis efetuada na secção anterior, vamos analisar os resultados das previsões do ROA com recurso a dados subsetoriais.

Cada um dos cinco quintis funcionará como um subsetor. O objetivo é agrupar as empresas da amostra em subsectores e calcular os indicadores que compõem o ROA e as variáveis que os determinam com recurso a dados do subsetor correspondente e não do setor como um todo.

Cada empresa no subsetor respetivo apresenta uma maior semelhança entre os valores dos quatro indicadores e das variáveis que os determinam. Os subsectores são mais homogêneos do que o setor como um todo, onde as características financeiras das empresas líderes são substancialmente diferentes das empresas do fundo do setor. Desta forma, é nossa expectativa que as previsões efetuadas utilizando dados subsetoriais, sejam, em média, mais precisas que as previsões obtidas com dados setoriais.

Analisando os resultados globais das previsões do ROA para o total da amostra, constatamos que os resultados das medidas de precisão das previsões que utilizaram dados setoriais não são substancialmente diferentes das previsões que utilizaram dados subsetoriais.

Como podemos observar pelos resultados da Tabela 5.4-1, a utilização de dados subsetoriais melhorou todas as medidas de precisão face à utilização de dados do setor. Contudo, o número de empresas cujas previsões foram mais precisas com recurso aos dados subsetoriais desceu face ao número de empresas cujas previsões recorreram a dados setoriais, conforme mostra a Tabela 5.4-2. Assim, de acordo com os resultados obtidos, somos obrigados a rejeitar H_4 .

Tabela 5.4-1
Medidas de precisão das previsões do ROA (E, S e SS)

Medidas de precisão	E	P	S	P	SS	P	Δ^{21}
MSE	2,71%	3°	2,26%	2°	2,21%	1°	-2,15%
RMSE	16,47%	3°	15,04%	2°	14,87%	1°	-1,12%
MAE	9,45%	1°	10,60%	3°	10,39%	2°	-2,02%
MdAE	5,62%	1°	7,57%	3°	6,98%	2°	-7,82%
MAPE	219,76%	1°	250,70%	3°	234,96%	2°	-6,28%
MdAPE	57,03%	1°	69,37%	3°	68,66%	2°	-1,03%

Tabela 5.4-2
Número de empresas com previsão do ROA mais precisa por conjunto dados (E e SS)

Conjunto de dados	Nº de Empresas	Percentagem	Δ^{22}
E	178	61,17%	3,49%
SS	113	38,83%	-5,04%
Total da amostra	291	100,00%	

Decompondo a previsão do ROA, verificamos que, para a previsão do VN, o número de empresas cujas previsões foram mais precisas com a utilização de dados subsetoriais foi inferior quando comparamos com os resultados obtidos com a utilização de dados setoriais, como pode ser visto na Tabela 5.4-3.

²¹ Variação dos resultados das medidas de precisão dos dados subsetoriais face aos resultados dos dados setoriais.

²² Variação do número de empresas com previsão mais precisa face aos resultados obtidos da comparação entre dados da empresa e do setor.

Tabela 5.4-3**Número de empresas com previsão do VN mais precisa por conjunto dados (E e SS)**

Conjunto de dados	Nº de Empresas	Porcentagem	Δ
E	113	38,83%	13,00%
SS	178	61,17%	-6,81%
Total da amostra	291	100,00%	

Relativamente à precisão das previsões, houve algumas melhorias, nomeadamente na diminuição da amplitude do erro de previsão com recurso a dados subsetoriais. Apesar das restantes medidas apresentarem valores superiores às obtidas com recurso a dados setoriais, são, no entanto, inferiores às obtidas via dados da empresa. Como podemos constatar pelos resultados da Tabela 5.4-4, o MSE, o RMSE e o MAE, foram as únicas medidas que melhoraram com a utilização do novo conjunto de dados.

Tabela 5.4-4**Medidas de precisão das previsões do VN (E, S e SS)**

Medidas de precisão	VN						
	E	P	S	P	SS	P	Δ ²³
MSE	5.571.948,31	3°	4.372.150,49	2°	3.973.513,62	1°	-9,12%
RMSE	2.360,50	3°	2.090,97	2°	1.993,37	1°	-4,67%
MAE	948,937	3°	761,025	2°	752,12	1°	-1,17%
MdAE	383,346	3°	276,56	1°	319,07	2°	15,37%
MAPE	23,67%	3°	18,27%	1°	19,29%	2°	5,60%
MdAPE	14,56%	3°	12,20%	1°	13,12%	2°	7,59%

Ao analisarmos os resultados das medidas de precisão das previsões dos quatro indicadores apresentados na Tabela 5.4-5, constatamos que a utilização de dados subsetoriais torna as previsões destes indicadores mais precisas do que as previsões obtidas via dados setoriais.

²³ Variação dos resultados das medidas de precisão obtidos via dados subsetoriais face aos obtidos via dados do setor

Tabela 5.4-5**Medidas de precisão das previsões dos quatro indicadores (E, S e SS)**

Indicadores	Medidas de Precisão	Conjuntos de Dados						
		E	P	S	P	SS	P	Δ
TMB	MSE	0,49%	1°	1,77%	3°	1,47%	2°	-17,09%
	RMSE	7,00%	1°	13,32%	3°	12,13%	2°	-8,95%
	MAE	4,43%	1°	9,60%	3°	8,51%	2°	-11,31%
	MdAE	3,10%	1°	7,04%	3°	6,42%	2°	-8,74%
	MAPE	8,48%	1°	17,39%	3°	15,85%	2°	-8,86%
	MdAPE	6,11%	1°	14,46%	3°	13,26%	2°	-8,29%
ECC	MSE	0,53%	1°	1,22%	2°	1,22%	3°	0,12%
	RMSE	7,25%	1°	11,03%	2°	11,04%	3°	0,06%
	MAE	4,45%	1°	7,17%	3°	7,12%	2°	-0,78%
	MdAE	2,47%	1°	4,40%	3°	4,31%	2°	-2,14%
	MAPE	195,41%	1°	253,67%	3°	243,51%	2°	-4,00%
	MdAPE	35,71%	1°	35,71%	3°	35,71%	2°	0,00%
ROVN	MSE	0,15%	1°	0,35%	3°	0,35%	2°	-0,32%
	RMSE	3,89%	1°	5,90%	3°	5,89%	2°	-0,16%
	MAE	2,38%	1°	3,69%	3°	3,68%	2°	-0,32%
	MdAE	1,29%	1°	2,11%	2°	2,12%	3°	0,36%
	MAPE	190,48%	1°	199,71%	2°	200,42%	3°	0,36%
	MdAPE	36,57%	1°	64,22%	3°	60,84%	2°	-5,26%
GRA	MSE	935,48%	3°	659,53%	2°	489,93%	1°	-25,71%
	RMSE	305,86%	3°	256,81%	2°	221,34%	1°	-13,81%
	MAE	149,60%	3°	99,40%	2°	90,96%	1°	-8,49%
	MdAE	66,87%	3°	48,21%	1°	49,46%	2°	2,59%
	MAPE	43,40%	3°	29,79%	2°	27,36%	1°	-8,17%
	MdAPE	27,66%	3°	18,13%	2°	17,49%	1°	-3,53%

Conforme os resultados expostos na Tabela 5.4-5, as previsões do indicador GRA foram mais precisas com a utilização de dados subsetoriais, algo que nunca aconteceu com os outros conjuntos de dados utilizados. Este resultado sugere que, para as empresas da amostra, os valores do GRA convergem, numa primeira fase, para os valores subsetoriais, ou seja, das suas congêneres e, globalmente, os valores de cada subsetor são próximos, convergindo para o setor.

De realçar que não detetamos o efeito que sucedeu com a utilização de dados combinados, em que houve uma perda de precisão nas previsões que com dados setoriais já eram mais precisas do que as previsões com dados da empresa. Tanto nas previsões do

VN como nas do indicador GRA, a utilização de dados subsetoriais aumentou a precisão das previsões.

Resultados Primeiro Subsetor

Apesar de alguns ganhos na precisão das previsões do ROA no primeiro subsetor, a utilização de dados subsetoriais gerou previsões menos precisas do que as previsões que recorreram a dados da empresa. Os resultados da Tabela 5.4-6 demonstram que o ganho de precisão em cada indicador foi muito reduzido, em média cerca de 1,33%.

Tabela 5.4-6

Medidas de precisão das previsões do ROA para o primeiro subsetor (E, S e SS)

Medidas de precisão	1º Subsetor						
	E	P	S	P	SS	P	Δ^{24}
MSE	0,74%	1º	8,48%	3º	8,40%	2º	-0,88%
RMSE	8,60%	1º	29,11%	3º	28,98%	2º	-0,44%
MAE	5,38%	1º	8,48%	3º	8,40%	2º	-0,88%
MdAE	3,13%	1º	6,20%	3º	5,96%	2º	-3,89%
MAPE	124,36%	1º	228,67%	3º	226,32%	2º	-1,03%
MdAPE	45,40%	1º	69,19%	3º	68,60%	2º	-0,86%

Analisando os resultados das medidas de precisão das previsões do VN, constatamos que, para o 1º subsetor, a utilização de dados subsetoriais gerou previsões mais precisas do que aquelas obtidas via utilização de dados setoriais. Os resultados da Tabela 5.4-7 demonstram que as melhorias são de facto significativas.

A amplitude do erro, com a utilização de dados subsetoriais diminui substancialmente face à amplitude de erro verificada nas previsões dos outros conjuntos de dados.

Tabela 5.4-7

Medidas de precisão das previsões do VN para o primeiro subsetor (E, S e SS)

Medidas de precisão	1º Subsetor						
	E	P	S	P	SS	P	Δ
MSE	22.525.278,57	3º	20.262.730,83	2º	3.973.513,62	1º	-80,39%
RMSE	4.746,08	3º	4.501,41	2º	1.993,37	1º	-55,72%
MAE	2.240,46	3º	2.165,90	2º	752,12	1º	-65,27%
MdAE	806,19	2º	1.110,49	3º	319,07	1º	-71,27%
MAPE	23,82%	3º	23,26%	2º	19,29%	1º	-17,07%
MdAPE	12,24%	1º	15,86%	3º	13,12%	2º	-17,26%

²⁴ Variação dos resultados das medidas de precisão face aos resultados obtidos com dados setoriais.

Fazendo a decomposição do ROA nos quatro indicadores, verificamos que, em média, a utilização dos dados subsetoriais piorou as medidas de precisão dos quatro indicadores. O único indicador que beneficiou com esta nova utilização de dados foi o ROVN, porém os resultados das medidas de precisão continuam distantes dos resultados obtidos via utilização de dados da empresa conforme se pode observar na Tabela 5.4-8.

Tabela 5.4-8

Medidas de precisão das previsões dos quatro indicadores para o primeiro subsetor

Indicadores	Medidas de Precisão	Conjuntos de Dados						
		E	P	S	P	SS	P	Δ
TMB	MSE	0,35%	1°	1,06%	2°	1,21%	3°	13,72%
	RMSE	5,89%	1°	10,31%	2°	11,00%	3°	6,64%
	MAE	4,04%	1°	8,45%	2°	8,78%	3°	3,98%
	MdAE	2,99%	1°	7,23%	2°	8,31%	3°	14,87%
	MAPE	7,97%	1°	17,13%	3°	17,12%	2°	-0,03%
	MdAPE	6,31%	1°	14,21%	2°	17,02%	3°	19,75%
ECC	MSE	0,92%	1°	2,11%	3°	2,11%	2°	-0,22%
	RMSE	9,59%	1°	14,53%	3°	14,51%	2°	-0,11%
	MAE	5,54%	1°	9,07%	2°	9,10%	3°	0,28%
	MdAE	2,41%	1°	4,91%	3°	4,91%	2°	-0,11%
	MAPE	98,24%	1°	174,25%	2°	178,64%	3°	2,52%
	MdAPE	32,38%	1°	67,98%	3°	65,48%	2°	-3,68%
ROVN	MSE	0,20%	1°	0,52%	3°	0,51%	2°	-2,00%
	RMSE	4,50%	1°	7,23%	3°	7,16%	2°	-1,00%
	MAE	2,82%	1°	4,54%	3°	4,48%	2°	-1,36%
	MdAE	1,40%	1°	2,17%	3°	2,16%	2°	-0,31%
	MAPE	102,82%	1°	171,16%	3°	165,98%	2°	-3,03%
	MdAPE	36,57%	1°	66,87%	3°	64,78%	2°	-3,13%
GRA	MSE	58,55%	3°	39,94%	1°	43,88%	2°	9,86%
	RMSE	76,52%	3°	63,20%	1°	66,24%	2°	4,82%
	MAE	51,14%	3°	41,55%	1°	42,99%	2°	3,46%
	MdAE	25,17%	3°	23,07%	1°	23,56%	2°	2,13%
	MAPE	25,38%	3°	21,01%	1°	21,49%	2°	2,27%
	MdAPE	20,29%	3°	13,81%	2°	12,53%	1°	-9,31%

Resultados segundo Subsetor

Analisando os resultados do 2º subsetor constatamos que a utilização de dados subsetoriais piorou todas as medidas de precisão, em média 0,85%, quando comparadas com as medidas de precisão resultantes da utilização de dados setoriais. Os resultados da Tabela 5.4-9 demonstram que as previsões com dados subsetoriais obtiveram uma amplitude de erro e um peso relativo do erro na observação relativamente próximos dos resultados obtidos com dados setoriais.

Tabela 5.4-9

Medidas de precisão das previsões do ROA para o segundo subsetor (E, S e SS)

Medidas de precisão	2º Subsetor						
	E	P	S	P	SS	P	Δ
MSE	0,84%	1º	1,56%	2º	1,61%	1º	2,70%
RMSE	9,18%	1º	12,51%	2º	12,68%	1º	1,34%
MAE	6,64%	1º	9,48%	2º	9,57%	1º	0,98%
MdAE	4,82%	1º	7,27%	3º	6,96%	2º	-4,36%
MAPE	134,38%	1º	147,70%	2º	150,56%	1º	1,93%
MdAPE	48,54%	1º	74,62%	2º	76,51%	1º	2,53%

Relativamente às previsões do VN com recurso a dados subsetoriais, a perda de precisão é substancial em todas as medidas. Apesar da perda de precisão para as previsões com dados do setor, a amplitude do erro captada na medida MSE e MAE é ainda bastante inferior à obtida via dados da empresa, conforme podemos observar na Tabela 5.4-10.

Tabela 5.4-10

Medidas de precisão das previsões do VN para o segundo subsetor (E, S e SS)

Medidas de precisão	VN						
	E	P	S	P	SS	P	Δ
MSE	1.392.171,39	3º	688.304,67	1º	725.270,15	2º	5,37%
RMSE	1.179,90	3º	829,64	1º	851,63	2º	2,65%
MAE	829,48	3º	601,29	1º	632,95	2º	5,26%
MdAE	468,75	3º	405,32	1º	436,64	2º	7,73%
MAPE	20,61%	3º	15,38%	1º	16,48%	2º	7,12%
MdAPE	11,44%	2º	11,26%	1º	12,09%	3º	7,40%

Os quatro indicadores utilizados para cálculo do ROA demonstram, com a utilização de dados subsetoriais, algumas melhorias relativamente à precisão das previsões. Os indicadores TMB e GRA obtiveram, em média, um aumento de precisão face às previsões

via dados setoriais de 16,11% e 11,17% respetivamente. Os indicadores ECC e ROVN obtiveram, em média, uma diminuição de precisão face às previsões via dados setoriais de 2,96% e 3,80% respetivamente. Os resultados das medidas de precisão dos quatro indicadores para o 2º subsetor estão apresentados na Tabela 5.4-11.

Tabela 5.4-11

Medidas de precisão das previsões dos quatro indicadores para o segundo subsetor (E, S e SS)

Indicadores	Medidas de Precisão	Conjuntos de Dados						
		E	P	S	P	SS	Δ	P
TMB	MSE	0,24%	1º	0,94%	3º	0,78%	-17,48%	2º
	RMSE	4,92%	1º	9,71%	3º	8,82%	-9,16%	2º
	MAE	3,81%	1º	7,39%	3º	6,45%	-12,72%	2º
	MdAE	3,24%	1º	6,40%	3º	4,96%	-22,45%	2º
	MAPE	7,49%	1º	14,81%	3º	13,36%	-9,79%	2º
	MdAPE	5,94%	1º	12,68%	3º	9,50%	-25,04%	2º
ECC	MSE	0,91%	1º	2,01%	2º	2,06%	2,29%	3º
	RMSE	9,52%	1º	14,18%	2º	14,34%	1,14%	3º
	MAE	5,52%	1º	8,79%	2º	8,90%	1,31%	3º
	MdAE	2,97%	1º	4,33%	2º	4,65%	7,39%	3º
	MAPE	114,41%	2º	139,71%	2º	144,50%	3,43%	3º
	MdAPE	35,97%	1º	68,23%	2º	69,71%	2,17%	3º
ROVN	MSE	0,28%	1º	0,53%	2º	0,55%	3,29%	3º
	RMSE	5,26%	1º	7,28%	2º	7,40%	1,63%	3º
	MAE	2,91%	1º	4,38%	2º	4,45%	1,52%	3º
	MdAE	1,30%	1º	2,27%	2º	2,49%	9,94%	3º
	MAPE	113,99%	2º	124,86%	2º	130,75%	4,72%	3º
	MdAPE	34,31%	1º	69,49%	2º	70,65%	1,67%	3º
GRA	MSE	113,63%	3º	62,15%	2º	53,57%	-13,81%	1º
	RMSE	106,60%	3º	78,84%	2º	73,19%	-7,16%	1º
	MAE	84,17%	3º	56,86%	2º	52,31%	-8,01%	1º
	MdAE	63,83%	3º	39,74%	2º	32,14%	-19,12%	1º
	MAPE	38,03%	3º	26,13%	2º	23,66%	-9,45%	1º
	MdAPE	26,80%	3º	18,36%	2º	16,63%	-9,44%	1º

Resultados terceiro Subsetor

Os resultados das medidas de precisão das previsões do ROA para o terceiro subsetor, que corresponde a empresas de dimensão média, obtiveram melhorias significativas com a utilização de dados subsetoriais, essencialmente no peso relativo do erro na observação.

Porém, a amplitude do erro aumentou com a utilização de dados subsetoriais face aos resultados obtidos via dados setoriais.

Neste subsetor, a menor amplitude de erro foi alcançada com a utilização de dados setoriais e o menor peso relativo foi alcançado via utilização de dados da empresa, de acordo com os resultados da Tabela 5.4-12.

Tabela 5.4-12

Medidas de precisão das previsões do ROA para o terceiro subsetor (E, S e SS)

Medidas de precisão	3° Subsetor						
	E	P	S	P	SS	P	Δ
MSE	3,35%	3°	1,46%	1°	1,51%	2°	3,38%
RMSE	18,29%	3°	12,07%	1°	12,27%	2°	1,67%
MAE	9,08%	3°	8,44%	1°	8,44%	2°	0,10%
MdAE	4,63%	1°	5,66%	3°	4,90%	2°	-13,40%
MAPE	209,05%	1°	274,53%	3°	250,87%	2°	-8,62%
MdAPE	58,97%	1°	81,02%	3°	77,83%	2°	-3,94%

A previsão do VN com dados subsetoriais foi, neste 3° subsetor, menos precisa do que com dados setoriais. Os resultados da Tabela 5.4-13 sugerem que à medida que a dimensão da empresa vai diminuindo, as previsões obtidas com dados subsetoriais vão perdendo precisão, ao contrário do que se passa com a utilização de dados setoriais que, como vimos, vão atingir o seu ponto ótimo em termos de precisão no quinto quintil²⁵.

Tabela 5.4-13

Medidas de precisão das previsões do VN para o terceiro subsetor (E, S e SS)

Medidas de precisão	VN						
	E	P	S	P	SS	P	Δ
MSE	3.280.969,70	3°	649.494,35	1°	726.541,47	2°	11,86%
RMSE	1.811,34	3°	805,91	1°	852,37	2°	5,77%
MAE	935,35	3°	538,52	1°	569,58	2°	5,77%
MdAE	412,24	3°	313,23	1°	313,42	2°	0,06%
MAPE	27,20%	3°	20,17%	1°	21,69%	2°	7,56%
MdAPE	16,83%	2°	11,45%	1°	10,96%	3°	-4,21%

Analisando os quatro indicadores, constatamos que houve uma melhoria na precisão das previsões de todos eles com a utilização de dados subsetoriais, conforme os resultados da Tabela 5.4-14.

²⁵ Equivalente ao quinto Subsetor

Tabela 5.4-14

Medidas de precisão das previsões dos quatro indicadores para o terceiro subsetor (E, S e SS)

Indicadores	Medidas de Precisão	Conjuntos de Dados						
		E	P	S	P	SS	Δ	P
TMB	MSE	0,40%	1°	0,93%	3°	0,75%	-18,90%	2°
	RMSE	6,31%	1°	9,63%	3°	8,68%	-9,95%	2°
	MAE	4,54%	1°	7,45%	3°	6,42%	-13,73%	2°
	MdAE	3,67%	1°	5,67%	2°	5,81%	2,47%	3°
	MAPE	9,48%	1°	14,19%	3°	12,66%	-10,81%	2°
	MdAPE	7,10%	1°	12,39%	3°	11,03%	-10,94%	2°
ECC	MSE	0,23%	1°	0,46%	3°	0,44%	-2,84%	2°
	RMSE	4,76%	1°	6,75%	3°	6,65%	-1,43%	2°
	MAE	3,22%	1°	5,05%	3°	4,96%	-1,74%	2°
	MdAE	1,87%	1°	4,22%	3°	3,68%	-12,83%	2°
	MAPE	120,87%	1°	231,79%	3°	211,11%	-8,92%	2°
	MdAPE	40,10%	1°	62,55%	3°	65,04%	3,99%	2°
ROVN	MSE	0,06%	1°	0,12%	2°	0,12%	0,95%	3°
	RMSE	2,35%	1°	3,44%	2°	3,46%	0,47%	3°
	MAE	1,53%	1°	2,51%	2°	2,57%	2,23%	3°
	MdAE	0,84%	1°	1,83%	2°	1,97%	7,52%	3°
	MAPE	111,48%	1°	210,67%	3°	203,99%	-3,17%	2°
	MdAPE	36,29%	1°	68,18%	3°	63,41%	-6,99%	2°
GRA	MSE	588,87%	3°	201,09%	2°	171,94%	-14,50%	1°
	RMSE	242,67%	3°	141,81%	2°	131,12%	-7,53%	1°
	MAE	142,07%	3°	87,78%	2°	85,43%	-2,68%	1°
	MdAE	76,36%	3°	49,49%	1°	50,24%	1,51%	2°
	MAPE	48,84%	3°	29,68%	2°	29,39%	-0,98%	1°
	MdAPE	33,47%	3°	17,22%	1°	18,38%	6,75%	2°

Apesar da melhoria na precisão, as previsões com dados da empresa continuam a ser mais precisas para os indicadores TMB, ECC e ROVN, sendo apenas o indicador GRA mais preciso via a utilização de dados subsetoriais.

Resultados quarto Subsetor

Os resultados das medidas de precisão das previsões do ROA via utilização de dados subsetoriais revelam um aumento substancial na precisão das previsões face às obtidas via

dados setoriais. Tanto a amplitude do erro de previsão como o peso relativo do erro na observação são agora inferiores com a utilização de dados subsetoriais.

Os resultados da Tabela 5.4-15 não evidenciam, de uma forma clara, qual o conjunto de dados que obteve as previsões mais precisas. A medida MSE, RMSE e MdAPE indicam os dados subsetoriais, enquanto as medidas MAE, MdAE e MAPE indicam os dados da empresa.

Tabela 5.4-15

Medidas de precisão das previsões do ROA para o quarto subsetor (E, S e SS)

Medidas de precisão	4º Subsetor						
	E	P	S	P	SS	P	Δ
MSE	1,42%	3º	1,29%	2º	1,19%	1º	-7,72%
RMSE	11,92%	3º	11,35%	2º	10,90%	1º	-3,94%
MAE	8,28%	1º	9,27%	3º	8,60%	2º	-7,26%
MdAE	6,42%	1º	8,69%	3º	7,19%	2º	-17,23%
MAPE	153,50%	1º	254,07%	3º	214,41%	2º	-15,61%
MdAPE	64,53%	2º	77,11%	3º	61,00%	1º	-20,90%

Relativamente às previsões do VN via a utilização de dados subsetoriais houve uma perda de precisão. Conforme se pode constatar pelos resultados da Tabela 5.4-16, houve um ligeiro aumento da amplitude do erro face ao obtido via utilização de dados setoriais.

Tabela 5.4-16

Medidas de precisão das previsões do VN para o quarto subsetor (E, S e SS)

Medidas de precisão	VN						
	E	P	S	P	SS	P	Δ
MSE	349.674,74	3º	174.487,23	1º	187.200,83	2º	7,29%
RMSE	591,33	3º	417,72	1º	432,67	2º	3,58%
MAE	399,32	3º	274,95	1º	294,41	2º	7,08%
MdAE	299,89	3º	180,82	1º	182,53	2º	0,95%
MAPE	22,95%	3º	16,31%	1º	18,12%	2º	11,07%
MdAPE	17,25%	3º	12,15%	1º	13,59%	2º	11,91%

Decompondo o ROA nos quatro indicadores que o determinam, constatamos, pelos resultados da Tabela 5.4-17, que globalmente houve uma melhoria significativa nas medidas de precisão. Apesar dessa melhoria, para os indicadores TMB, ECC e ROVN, os dados da empresa continuam a produzir previsões mais precisas.

Tabela 5.4-17

Medidas de precisão das previsões dos quatro indicadores para quarto subsetor (E, S e SS)

Indicadores	Medidas de Precisão	Conjuntos de Dados						
		E	P	S	P	SS	Δ	P
TMB	MSE	0,85%	1°	2,28%	3°	1,72%	-24,47%	2°
	RMSE	9,24%	1°	15,09%	3°	13,11%	-13,09%	2°
	MAE	4,61%	1°	10,81%	3°	9,02%	-16,63%	2°
	MdAE	2,42%	1°	7,13%	3°	6,27%	-12,13%	2°
	MAPE	7,74%	1°	17,69%	3°	15,09%	-14,66%	2°
	MdAPE	4,78%	1°	14,76%	3°	13,48%	-8,70%	2°
ECC	MSE	0,22%	1°	0,63%	3°	0,60%	-4,28%	2°
	RMSE	4,70%	1°	7,95%	3°	7,78%	-2,16%	2°
	MAE	3,48%	1°	5,88%	3°	5,58%	-5,09%	2°
	MdAE	2,04%	1°	4,16%	3°	3,79%	-8,98%	2°
	MAPE	134,89%	1°	258,95%	3°	227,59%	-12,11%	2°
	MdAPE	32,75%	1°	65,87%	3°	58,10%	-11,80%	2°
ROVN	MSE	0,07%	1°	0,21%	3°	0,20%	-1,78%	2°
	RMSE	2,71%	1°	4,56%	3°	4,51%	-0,89%	2°
	MAE	1,94%	1°	3,16%	3°	3,08%	-2,55%	2°
	MdAE	1,12%	1°	2,13%	3°	1,95%	-8,52%	2°
	MAPE	129,30%	1°	214,95%	3°	202,28%	-5,90%	2°
	MdAPE	34,55%	1°	58,26%	3°	55,02%	-5,56%	2°
GRA	MSE	420,21%	3°	289,34%	2°	257,24%	-11,10%	1°
	RMSE	204,99%	3°	170,10%	2°	160,39%	-5,71%	1°
	MAE	141,01%	3°	95,20%	2°	86,60%	-9,03%	1°
	MdAE	84,35%	3°	55,65%	2°	52,22%	-6,16%	1°
	MAPE	40,79%	3°	29,18%	2°	25,76%	-11,71%	1°
	MdAPE	28,40%	3°	19,05%	2°	16,67%	-12,46%	1°

Resultados quinto Subsetor

Este subsetor é composto pelas empresas de menor dimensão e com taxas de crescimento do VN superiores às dos outros subsetores.

Como podemos constatar na Tabela 5.4-18, a utilização de dados subsetoriais gerou previsões mais precisas do que as obtidas via os outros dois conjuntos de dados.

Tabela 5.4-18**Medidas de precisão das previsões do ROA para quinto subsetor (E, S e SS)**

Medidas de precisão	5° Subsetor						
	E	P	S	P	SS	P	Δ
MSE	7,25%	3°	5,48%	2°	5,26%	1°	-3,99%
RMSE	26,93%	3°	23,41%	2°	22,94%	1°	-2,01%
MAE	17,88%	3°	17,30%	2°	16,92%	1°	-2,22%
MdAE	13,09%	3°	12,05%	2°	10,99%	1°	-8,78%
MAPE	479,96%	3°	350,71%	2°	335,06%	1°	-4,46%
MdAPE	64,11%	3°	59,10%	1°	62,64%	2°	6,00%

Relativamente às previsões do VN, a utilização de dados subsetoriais piorou significativamente a precisão das previsões, conforme se pode observar pelos resultados da Tabela 5.4-19. De realçar que apesar da perda de precisão face aos dados setoriais, as previsões com dados subsetoriais são, substancialmente, mais precisas que as previsões com dados da empresa.

Tabela 5.4-19**Medidas de precisão das previsões do VN para quinto subsetor (E, S e SS)**

Medidas de precisão	VN						
	E	P	S	P	SS	P	Δ
MSE	403.006,00	3°	158.833,93	1°	164.778,39	2°	3,74%
RMSE	634,83	3°	398,54	1°	405,93	2°	1,85%
MAE	347,42	3°	231,31	1°	239,31	2°	3,46%
MdAE	182,94	3°	126,45	1°	141,83	2°	12,16%
MAPE	23,95%	3°	16,37%	1°	18,38%	2°	12,23%
MdAPE	16,81%	3°	12,27%	1°	14,86%	2°	21,12%

Nas previsões dos quatro indicadores, no global, a utilização de dados subsetoriais aumentou a precisão das previsões. A Tabela 5.4-20 apresenta os resultados das medidas de precisão para os três conjuntos de dados utilizados.

Tabela 5.4-20

Medidas de precisão das previsões dos quatro indicadores para o quinto subsetor (E, S e SS)

Indicadores	Medidas de Precisão	Conjuntos de Dados						
		E	P	S	P	SS	Δ	P
TMB	MSE	0,62%	1°	3,68%	3°	2,90%	-21,11%	2°
	RMSE	7,84%	1°	19,18%	3°	17,03%	-11,18%	2°
	MAE	5,14%	1°	13,89%	3°	11,84%	-14,79%	2°
	MdAE	3,72%	1°	5,83%	3°	5,66%	-2,80%	2°
	MAPE	9,63%	1°	22,99%	3°	20,75%	-9,73%	2°
	MdAPE	6,80%	1°	21,75%	3°	14,37%	-33,95%	2°
ECC	MSE	0,36%	1°	0,90%	2°	0,90%	0,61%	3°
	RMSE	6,03%	1°	9,47%	2°	9,50%	0,31%	3°
	MAE	4,56%	1°	7,19%	3°	7,14%	-0,76%	2°
	MdAE	3,37%	1°	5,46%	3°	5,16%	-5,45%	2°
	MAPE	511,66%	2°	467,95%	2°	459,57%	-1,79%	1°
	MdAPE	37,66%	1°	61,82%	3°	58,86%	-4,78%	2°
ROVN	MSE	0,15%	1°	0,37%	3°	0,36%	-2,71%	2°
	RMSE	3,89%	1°	6,06%	3°	5,98%	-1,37%	2°
	MAE	2,71%	1°	3,92%	3°	3,89%	-0,80%	2°
	MdAE	1,85%	1°	2,46%	2°	2,53%	3,02%	3°
	MAPE	497,46%	3°	279,98%	1°	302,46%	8,03%	2°
	MdAPE	39,62%	1°	61,40%	3°	57,80%	-5,86%	2°
GRA	MSE	3510,18%	3°	2700,27%	2°	1916,62%	-29,02%	1°
	RMSE	592,47%	3°	519,64%	2°	437,79%	-15,75%	1°
	MAE	330,27%	3°	212,03%	2°	183,97%	-13,23%	1°
	MdAE	114,34%	3°	95,43%	2°	70,96%	-25,64%	1°
	MAPE	64,18%	3°	42,00%	2°	35,55%	-15,36%	1°
	MdAPE	36,56%	3°	23,55%	2°	20,29%	-13,86%	1°

O aumento da precisão das previsões mais significativo foi no indicador GRA. Apesar do aumento de precisão nos restantes indicadores, os dados da empresa continuam a produzir previsões mais precisas.

6. Conclusão

6.1. Conclusões

O principal objetivo deste Trabalho é perceber qual a importância dos dados setoriais na previsão financeira e como os podemos utilizar para aumentar a precisão das previsões financeiras na ótica do apoio à tomada de decisão por parte da equipa de gestão. De facto, de acordo com os resultados obtidos, podemos concluir que os dados setoriais podem aumentar a precisão das previsões financeiras.

Para apurarmos a sua importância, estudamos os efeitos provocados na previsão do ROA utilizando cinco conjuntos de dados:

- Históricos da empresa;
- Históricos do setor;
- Combinação de dados históricos da empresa e do setor:
 - Previsão apenas do volume de negócios com dados setoriais e restantes com dados da empresa (cenário base);
 - Combinação de dados históricos da empresa e do setor para todas as variáveis (teste de robustez);
- Históricos subsetoriais.

Para o indicador ROA verificamos que a utilização de dados setoriais, apesar de apresentar uma amplitude de erro e um peso relativo do erro na observação superiores aos obtidos via dados da empresa, para aproximadamente 41% da amostra obteve previsões mais precisas, contudo, de acordo com os resultados, somos obrigados a rejeitar *H1*. A Tabela 6.1-1 mostra, para o total da amostra, qual o número de empresas que cada conjunto de dados melhor previu o ROA.

Tabela 6.1-1**Número de empresas com previsão do ROA mais precisa para o total da amostra por conjunto de dados**

Conjunto de dados	Nº de previsões mais precisas	Em percentagem da amostra
CI	83	28,52%
E	71	24,40%
S	49	16,84%
SS	46	15,81%
C2	42	14,43%
Total	291	100,00%

Relativamente à previsão do VN, as previsões obtidas via dados setoriais, foram, para cerca de 66% da amostra, mais precisas com a utilização de dados do setor do que com dados da empresa. Este resultado sugere que, na nossa amostra, há uma convergência do crescimento das vendas para a média setorial. A decomposição do ROA nos quatro indicadores que o determinam revela que apenas o indicador GRA é melhor previsto com dados setoriais. Este resultado sugere que a rotatividade do ativo converge para a média setorial. A indústria do calçado em Portugal é composta por um conjunto de empresas relativamente semelhantes em dimensão, estrutura organizativa, características da mão-de-obra e da maquinaria utilizada, o que sustenta a ideia, sugerida pela melhor previsão do GRA com dados setoriais, de que a eficácia verificada no setor é transversal às empresas que o compõe.

A combinação de dados setoriais com dados da empresa veio traduzir-se em ganhos de precisão significativos tanto para a previsão do ROA e dos indicadores que o determinam como para o VN. O cenário base demonstrou um aumento significativo na precisão das previsões do ROA obtidas via dados combinados face às previsões obtidas via dados da empresa. Uma vez que a única diferença entre os dois conjuntos de dados utilizados era a previsão do VN, os resultados das medidas de precisão não diferem significativamente, porém tanto a amplitude do erro como o peso relativo do erro na observação foram, com recurso a dados combinados, inferiores do que os obtidos via dados da empresa e via dados setoriais. Apesar deste ganho de precisão na previsão do ROA, relativamente à previsão do GRA este piorou a precisão face à obtida via dados setoriais, contudo permaneceu significativamente mais precisa do que as previsões obtidas via dados da empresa.

O teste de robustez realizado aos dados setoriais passou pela combinação, em todas as variáveis em causa, dos dados da empresa com os setoriais. Desta forma, os ganhos de precisão foram significativos. Para a previsão do ROA, a amplitude do erro foi menor com a utilização de dados combinados e o peso relativo do erro na observação foi superior ao obtido via dados da empresa. Estes resultados foram melhores para a combinação de dados do que os obtidos via dados setoriais, sugerindo uma importância significativa dos dados setoriais para o aumento de precisão das previsões financeiras. Assim, de acordo com os resultados, não rejeitamos *H2*.

A previsão do VN com dados combinados segunda fase obteve, para aproximadamente 69% da amostra, uma maior precisão do que aquela obtida com recurso a dados da empresa, não tendo no entanto sido mais precisa do que aquela obtida via dados setoriais. Desta forma, de acordo com os resultados, não rejeitamos *H3*.

Decompondo o ROA nos quatro indicadores que o determinam verificamos que:

- A precisão das previsões da TMB, do ECC e do ROVN melhorou face à obtida com dados setoriais;
- A precisão do indicador GRA piorou face à obtida com dados setoriais.

Estes resultados sugerem que a TMB, o ECC e o ROVN detêm alguma especificidade própria de empresa e não convergem para o setor, enquanto o GRA, como já vimos converge.

A análise da amostra por quintis sugere que há uma relação entre a dimensão da empresa e a capacidade preditiva dos dados utilizados. Para a previsão do ROA, à medida que a dimensão da empresa vai diminuindo na amostra, o número de empresas cuja precisão das previsões foi maior baseadas na utilização de dados da empresa e combinados (cenário base) vai diminuindo, enquanto o número de empresas em que as previsões foram mais precisas obtidas via dados setoriais vão aumentando. O número de empresas cujas previsões foram mais precisas obtidas via dados combinados C2 manteve-se constante ao longo de toda a amostra. Assim, de acordo com os resultados, rejeitamos *H5*.

A inclusão de dados subsetoriais no processo de previsão financeira permitiu aproximar na amostra a realidade interna e externa das empresas em grupos mais homogêneos.

Desta forma, os dados subsetoriais obtidos representam melhor a realidade da empresa relativamente ao subsetor a que pertencem. A organização em subsetores foi feita à semelhança da ordenação das empresas que fizemos para a análise por quintis.

Os resultados da previsão do ROA obtidos sugerem que, para o total da amostra, todas as medidas de precisão melhoraram face aos resultados obtidos via dados setoriais. Porém, contrariamente a esta indicação de melhor precisão, quando comparamos as previsões obtidas com dados da empresa e subsetoriais, o número de empresas cuja previsão foi mais precisa com recurso a um dos dois conjuntos de dados baixou 5,04% face ao número de empresas obtido com dados do setor. Desta forma, de acordo com os resultados, rejeitamos $H4$.

Na previsão do VN a descida foi mais acentuada, aproximadamente 7%, apesar de os resultados das medidas de precisão terem sido melhores que os obtidos com dados do setor. Relativamente à previsão dos quatro indicadores, a utilização de dados setoriais obteve melhores resultados do que os obtidos com recurso a dados setoriais, registando uma melhoria mais acentuada nos indicadores TMB e GRA.

Analisando individualmente cada subsetor constatamos que, para as previsões do ROA, houve melhorias face aos resultados obtidos com dados do setor e essas melhorias foram mais acentuadas no quarto e quinto quintil. Contudo, para o VN, apenas para o primeiro subsetor se verificaram melhorias. Essas melhorias foram, no entanto, substanciais, sugerindo que a convergência para a média subsetorial é maior do que para a média setorial nas empresas de maior dimensão da amostra.

6.2. Contributos

O contributo deste Trabalho para a literatura das Finanças Empresariais é, essencialmente, feito em duas vertentes:

- Numa primeira vertente, este Trabalho vem preencher uma lacuna existente na atual literatura financeira sobre previsão. A atual corrente de investigação passa pelo estudo de novos modelos de previsão, cada vez mais complexos e apoiados em teorias pertencentes a outros ramos da ciência, nomeadamente as redes neuronais, para aumento da precisão das previsões. Este Trabalho baseia-se na

teoria económica e financeira, respeitando a sua essência, e apresenta uma perspetiva simples, expedita e inovadora para o aumento da precisão das previsões financeiras.

- Numa segunda vertente, este Trabalho demonstra a importância dos dados setoriais no aumento da precisão das previsões financeiras de indicadores de eficiência como o ROA. Este estudo revela que, em setores como o utilizado neste Trabalho, a combinação de dados da empresa com dados do setor apresenta uma maior capacidade preditiva do ROA e do VN do que os dois conjuntos isolados. Estes resultados podem ser particularmente úteis para o aumento da precisão dos estudos de avaliação de empresas.

6.3. Limitações e sugestões para investigação futura

A maior e principal limitação deste Trabalho reside inexistência de estudos empíricos sobre este tema, o que impossibilita a comparação de resultados e metodologias utilizadas. Outra limitação encontrada foi a falta de informação adicional sobre as empresas da amostra, nomeadamente a maturidade de cada uma. Com essa informação poderíamos ter investigado qual a relação entre a maturidade da empresa e a precisão das previsões obtidas com recurso aos cinco conjuntos de dados utilizados.

Face às limitações enunciadas, uma sugestão evidente passa pelo estudo do impacto da utilização de dados setoriais na previsão financeira em outros setores de atividade, utilizando a mesma metodologia deste Trabalho, para se poder concluir se os resultados aqui presentes se mantêm.

Outra sugestão poderá ser a utilização de outras metodologias, nomeadamente a utilização de modelos mais complexos, como forma de determinar se a capacidade preditiva dos dados setoriais apresentada neste Trabalho é de alguma forma influenciada pela escolha do modelo de previsão utilizado. Além disto, sugere-se ainda o aumento do número de anos de previsão de forma a se poder determinar se o grau de precisão das previsões de longo prazo com dados setoriais é superior ao dos dados da empresa.

Por último, sugerimos também que se possa estudar o impacto da utilização dos dados setoriais na previsão financeira de outras variáveis além do ROA, por exemplo, dos *Free Cash-Flows* na ótica da avaliação de empresas.

Bibliografia

I - Livros

Cochrane, J. H. 2000. **Asset Pricing**. Princeton, New Jersey 08540: Princeton University Press

Horngren, C. T., Sundem, G. L., & Stratton, W. 1999. **Introduction to Management Accounting**. Upper Saddle River, NJ: Prentice Hall.

Shim, J. K., & Siegel, J. G. 2008a. **Budgeting Basics and Beyond** (3^a ed.). Hoboken, New Jersey: John Wiley & Sons, Inc.

Shim, J. K., Siegel, J. G. & Dauber, N. 2008b. **Corporate controller's handbook of financial management**. CCH.

II - Capítulos de Livros

Armstrong, J. S. 2008. Combining forecasts. In Armstrong, J. S. (Ed.) **Principles of Forecasting: A Handbook for Researchers and Practitioners**: 417-440 Norwell, MA: Kluwer Academic Publishers.

Armstrong, J. S. 2009. Selecting Forecasting Methods. In Armstrong, J. S. (Ed.) **Principles of Forecasting: A Handbook for Researchers and Practitioners**: 365-386 Norwell, MA: Kluwer Academic Publishers.

Armstrong, J. S. 1983. Strategic Planning And Forecasting Fundamentals. In Kenneth Albert (Ed.) **The Strategic Management Handbook**: 2-32. New York: McGraw Hill.

Besley, S. & Brigham, E. F. 2011. Financial planning and control. **Principles of Finance (4^a Ed.)**: 267-310. Mason, OH: South-Western Cengage Learning

Evans, M. K. 2003. Choosing the right type of forecasting model. In Agnew J.C. & Rosenzweig R. (Ed.) **Practical Business Forecasting**: 3-28. Blackwell Publishers Ltd.

Fabozzi, F. J., & Peterson, P. P. 2003. Strategy and Financial Planning. In F. J. Fabozzi, & P. P. Peterson (Ed.) **Financial Management and Analysis, 2**: 933-974. New Jersey: Wiley.

Han, J., Kamber, M., & Pei, J. 2011. Outlier Detection. **Data Mining Concepts and Techniques, 3**: 543-584. Waltham, MA 02451: Morgan Kaufmann Publishers.

Hoshmand, A. R. 2010. Forecasting for management decisions: An introduction. In Hoshmand, A. R. (Ed.) **Business Forecasting: A Practical Approach, 2**: 2-4. New York 10016: Routledge.

Jain, C. L., & Malehorn, J. 2006. Forecasting process. In C. L. Jain, & J. Malehorn (Ed.) **Benchmarking Forecasting Practices: A Guide to Improving Forecasting Performance, 3**: 24-45. Flushing, New York: Graceway Publishing Company, Inc.

Shim, J. K., & Siegel, J. G. 2006. Financial modeling - simulation. **Handbook of Financial Analysis, Forecasting and Modeling (3^a ed)**: 353-368. Chicago: CCH.

Tjia, J. S. 2004. Design Principles for Good Model Building. **Building Financial Models: A Guide to Creating and Interpreting Financial Statements**: 13-22. McGraw-Hill.

III - Artigos publicados em revista científica

Baker, M. J. 1999. Sales Forecasting. In Baker, M. J. (Ed.) **The IEBM Encyclopedia of Marketing**: 278-290. International Thompson Business Press.

Carbone, R., & Armstrong, J. S. 1982. Evaluation of Extrapolative Forecasting Methods: Results of a Survey of Academicians and Practitioners. **Journal of Forecasting, 1**: 215-217

Cassar, G., & Gibson, B. 2008. Budgets, Internal Reports and Manager Forecast Accuracy. **Contemporary Accounting Research, 25 (3)**: 707-738

Chambers, J. C., Mullick, S., & Smith, D. D. 1971. How to choose the right forecasting technique. *Harvard Business Review* , **49**: 45-71

Chenhall, R. H. 2003. Management Control systems design within its organizational context: findings from contingency-based research and directions for the future. *Accounting, Organizations and Society*, **28**: 127-168

Armstrong, J. S. & F. Collopy. 1992. Error measures for generalizing about forecasting methods: Empirical comparisons. *International Journal of Forecasting*, **8**: 69-80.

Dalrymple, D. J. 1975. Sales forecasting: Methods and accuracy. *Business Horizons*, **18**: 69-73.

Dalrymple, D. J. 1987. Sales forecasting practices: Results from a U.S. survey. *International Journal of Forecasting*, **3(3-4)**: 379-391

De Masi, P. 1996. The Dificult Art of Economic Forecasting. In Clift J. (Ed.) *Finance & Development* , **33**: 29-31

Fama, E. F. 1970. Efficient Capital Markets: A Review of Theory and Empirical Work. *Journal of Finance*, **25 (2)**: 383-417

Fama, E. F., & French, K. R. 2004. The Capital Asset Pricing Model: Theory and Evidence. *Journal of Economic Perspectives*, **18 (3)**: 25-46.

Fama, E. F., & Miller, M. H. 1972. *The Theory of Finance*. Hinsdale, Illinois: Dryden Press.

Harvard Business School. 2005. Budgeting: Forecasting your company's financial future. *Harvard Business School, Business literacy for HR professionals: The essentials of finance and budgeting*: 155-190. Harvard Business School Publishing Corporation and the Society for Human Resource Management.

Hoover, J. 2009. How to track forecast accuracy to guide forecast process improvement. *Foresight*, **14**:17-23.

Makridakis, S. 1996. Forecasting: its role and value for planning and strategy. *International Journal of Forecasting*, **12 (4)**: 513-537.

Perold, A. F. 2004. The Capital Asset Pricing Model. *Journal of Economic Perspectives*, **18 (3)**: 3-24.

Revista Capital Aberto. 2005. Prazos menores para balanços aproximam lucros das projecções. Fevereiro, 18: 40.

Sharpe, W. F. 1964. Capital Asset Prices: A theory of market equilibrium under conditions of risk. *Journal of Finance*, **19 (3)**: 425-442.

Yokum, J.T., & Armstrong J. S. 1995. Beyond accuracy: Comparison of criteria used to select forecasting methods. *International Journal of Forecasting*, **11**: 591-597

IV - Working Papers

Armstrong, J. S., & Green, K. C. 2011. *Demand Forecasting: Evidence-based methods*. <http://marketing.wharton.upenn.edu/ideas/pdf/Armstrong/DemandForecasting.pdf>, Outubro, 2011

Arsham, H. 1994. *Time-Critical Decision Making for Business Administration*. Outubro, 2011 <http://home.ubalt.edu/ntsbarsh/stat-data/forecast.htm#rgintroduction>

Derman, E., & Wilmott, P. 2009. *The Financial Modelers' Manifesto*. Working Paper. Disponível em: http://papers.ssrn.com/sol3/papers.cfm?abstract_id=1324878

De Gooijer, J., & Hyndman, R. J. 2005. **25 years of IFF time series forecasting: A selective review**. Working Paper No. TI 05-068/4. Tinbergen Institute

Gorton, G. B. 2008. **The panic of 2007**. Working Paper No. 08-24, Yale School of Management, New Haven, CT.

Hogarth, M. R. 2006. **On ignoring scientific evidence: The bumpy road to enlightenment**. Working Paper, ICREA & Pompeu Fabra University, Barcelona.

Hyndman, R. J. 2009. Business forecasting methods.

Hyndman, R. J., & Koehler, A. B. 2005. Another look at measures of forecast accuracy.

Schill, M. 2005. *The thoughtful forecaster*. UVA-F-1490. University of Virginia Darden School Foundation.

V - Informação disponível em sites da internet

APICCAPS. 2010. *Calçado, Componentes e artigos de Pele - Monografia Estatística 2009*. ISBN 978-989-96477-1-8
<http://portugueseshoes.pt/estatisticas/monografia2009.pdf>; Obtido em 03 de Outubro de 2011.

INE. 2010. *Estudos sobre estatísticas estruturais das empresas 2008*.
<http://www.iapmei.pt/resources/download/mpme2010.pdf>; Obtido em 29 de Novembro de 2011.

Vadasz, T. 2005. *Accurate Forecasting: A Fundamental Part of Financial Management*. http://www.s-ox.com/dsp_getFeaturesDetails.cfm?CID=465; Obtido em 18 de Agosto de 2011

Laurence, P. 1977. QFinance The Ultimate Financial Resource.
<http://www.qfinance.com/finance-and-business-quotes/forecasting>; Obtido em 15 de Agosto de 2011