
Modelos de previsão de distress bancário na Zona Euro

Maria Mariana Camacho Gomes

Dissertação

Mestrado em Finanças e Fiscalidade

Orientada por:

Prof. Doutor Francisco Vitorino da Silva Martins

Prof. Doutor Elísio Fernando Moreira Brandão

Nota Bibliográfica

Maria Mariana Camacho Gomes, nascida a 13 de novembro de 1995, a uma segunda-feira muito tempestuosa, na ilha da Madeira.

Frequentou o Liceu Jaime Moniz, no Funchal, onde conseguiu reunir os esforços para ingressar, em 2013, na Licenciatura em Gestão na Universidade do Minho, onde teve um papel ativo na Associação de estudantes do seu curso. Graduou-se em 2016 com uma média de 16 valores. No mesmo ano, candidatou-se e ingressou no Mestrado em Finanças e Fiscalidade, pela nobre Universidade do Porto.

Agradecimentos

Agradeço aos meus pais por todos os esforços feitos ao longo destes 18 anos de estudo, onde nunca me faltou nada, nem incentivo, nem amor, e muito menos bons conselhos.

Ao meu namorado, Fábio, que em muitos dias foi quem levou com o meu *stress*, mas que nunca deixou de me apoiar.

Ao meu irmão e aos meus poucos e chegados amigos, que me tiraram de casa para desanuviar e relaxar nos piores momentos.

Um grande obrigado ao meu orientador, Prof. Doutor Vitorino Martins, que sempre acreditou no meu trabalho e que me apoio e ajudou desde a primeira reunião. Agradeço também ao diretor de Mestrado, Prof. Doutor Elísio Brandão, pelo incentivo a fazer a dissertação desde os primeiros dias de Mestrado.

Resumo

A previsão de falência é um assunto que tem despertado o interesse de académicos, profissionais e legisladores, um pouco por todo o mundo e por todos os sectores. No setor bancário, apesar de nos últimos anos termos assistido a alguns casos de falências, não se trata de uma situação habitual, pelo que neste estudo trataremos da explicação e previsão de *distress* bancário na Zona Euro para o período de 2012 a 2017, a partir da informação de 4046 bancos europeus.

Nesta investigação serão desenvolvidos modelos para duas variáveis dependentes distintas: a primeira trata-se de uma variável de estado de falência retirada da base de dados Orbis Bank Focus, já a segunda é uma variável é definida pelos níveis mínimos dos rácios propostos no Acordo da Basileia III. Foram selecionadas como variáveis independentes as variáveis CAMELS (acrónimo para *Capital adequacy, Asset quality, Management competence, Earnings, Liquidity* e *Sensitivity to market risk*), macroeconómicas e bancárias. Foram elaborados vários modelos *logit*, na medida em que foram efetuados modelos com todas as variáveis, e modelos parciais incluindo apenas as variáveis CAMELS ou as outras variáveis, com desfasamentos temporais de um, dois e três anos antes do momento de *distress*. E, por último, foi elaborado um modelo através do método *stepwise-backward*, partindo da totalidade das variáveis e desfasamento temporal de um ano, de modo a obter um modelo apenas com variáveis estatisticamente significativas.

Concluiu-se que os modelos apresentados são importantes na explicação do *distress* bancário, tendo as variáveis Capital Próprio/Ativo, Rácio Tier1, ROAA, Depósitos e fundos de curto-prazo/Passivo, Empréstimos Concedidos/ Depósitos e fundos de curto-prazo, Rendimento de *trading*/Rendimento Operacional e a taxa de crescimento dos empréstimos concedidos têm uma relação inversa com a probabilidade de *distress*. Já as variáveis ROAE, Depósitos e fundos de curto-prazo/Ativo, Empréstimos/Passivo e a taxa de inflação apresentam coeficientes positivos na regressão de probabilidade de *distress*.

Palavras-chave: Logit, Previsão de falência, CAMELS, dados em painel, *distress* bancário

Abstract

Bankruptcy prediction is a subject that has aroused interest of academics, professionals and legislators all over the world and across several sectors. In the case of the banking sector, despite of the recent cases of bankruptcy, this is not a regular situation, so this study will cover the explanation and forecast of bank distress in the Eurozone for the period from 2012 to 2017, based on information of 4046 european banks.

In this investigation, models will be developed considering two different dependent variable: the first one is a status variable taken from Orbis Bank Focus database, the second is defined by the minimum levels of ratios proposed in Basel III. As independent variables we use CAMELS (acronym for Capital adequacy, Asset quality, Management competence, Earnings, Liquidity and Sensitivity to market risk), macroeconomic and banking variables. Several logit models were elaborated, since there were made models with all the variables and partial models including only the CAMELS variables or the other variables, with time lags of one, two and three years before the moment of distress. Lastly, a final model was elaborated through stepwise-backward method, from the model with with all the variables and time lag of one year, in order to obtain a model with only significant variables.

It was concluded that the presented models are important in explaining the banking distress, with the variables Equity/Assets, Tier1 Ratio, ROAA, Deposits and Short Term Funding/Liabilities, Loan/Deposits and Short Term Funding, Trading Revenue/Operating Revenue and Loan Grow have an inverse relation with the probability of distress. The variables ROAE, Deposits and Short Term Funding/Assets, Loan/Liabilities and Inflation present positive coefficients in the distress probability regression.

Keywords: Logit, Bankruptcy prediction, CAMELS, Panel data, bank distress

Índice

Nota Bibliográfica.....	ii
Agradecimentos	iii
Resumo	iv
Abstract.....	v
Índice de Tabelas	vii
1. Introdução	1
2. Revisão da literatura.....	4
2.1. Definição de bank ditress	9
3. Metodologia	11
3.1. Variáveis Utilizadas	11
3.2. Dados e amostra.....	17
3.3. Especificações do modelo	18
3.4. Hipóteses de investigação	20
4. Resultados Empíricos	21
4.1. Análise da Estatística Descritiva	21
4.2. Aplicação do Modelo.....	24
5. Conclusão	31
6. Referências Bibliográficas	33

Índice de Tabelas

Tabela 1- Descrição e sinal esperado das variáveis CAMELS	14
Tabela 2- Descrição e sinal esperado das variáveis não-CAMELS	16
Tabela 3- Bancos em <i>distress</i> , por ano (variável falência, Yfal).....	17
Tabela 4- Bancos em <i>distress</i> , por ano (variável rácio de capital, Ydis)	17
Tabela 5- Estatística Descritiva das variáveis explicativas, considerando a variável dependente falência (Yfal).....	21
Tabela 6- Estatística Descritiva das variáveis explicativas, considerando a variável dependente rácio de capital (Ydis)	22
Tabela 7- Resultados do modelo <i>Logit</i> - variável dependente falência (Yfal).....	25
Tabela 8- Resultados do modelo <i>Logit</i> - variável dependente rácio de capital (Ydis)	29
Tabela 9- Resultados do modelo <i>Logit</i> final - variável dependente rácio de capital - método <i>stepwise-backward</i>	30

1. Introdução

A recente crise financeira, que assolou quase todos os países no mundo, colocou o setor bancário sobre grande pressão, especialmente depois de 2007 quando vários grandes bancos norte-americanos foram apanhados no colapso imobiliário, desencadeando assim uma crise financeira que se arrastou até à Europa.

A previsão de falência bancária despertou o interesse de académicos, reguladores e profissionais da área. Os reguladores precisam de monitorizar a saúde financeira dos bancos, os profissionais tentam estimar ganhos e perdas possíveis, já os académicos tentam testar vários conceitos e perspetivas possíveis e avaliar as suas consequências.

Tendo em conta os custos substanciais relacionados com a falência bancária e as crises sistemáticas, monitorizar a probabilidade de falências bancárias é dos assuntos mais importantes para os bancos centrais e autoridades de supervisão bancária, em ordem de prever estes eventos. Poghosyan e Cihák (2009) defendem que existem dois potenciais usos para os *early warning system*: fortalecimento da importância das regras de supervisão bancária e a disciplina de mercado.

De acordo com Kane (1985), quando existe um grande número de falências bancárias, ou quando está em causa uma grande crise o público culpa os gestores dos bancos, pois estes não foram capazes de detetar as dificuldades e riscos que os bancos passam. Levando assim a que um dos objetivos deste trabalho é fornecer uma ferramenta que possa ajudar a prever *distress* bancários oportunamente.

Ao longo do tempo foram elaborados vários estudos, com diferentes métodos estatísticos, como modelos *Probit*, *Logit*, OLS, redes neurais e Análise Discriminante Múltipla e com diferentes variáveis explicativas, desde variáveis CAMELS (C- “Capital adequacy”, A- “Asset quality”, M- “Management competence”, E- “Earnings”, L- “Liquidity”, S- “Sensitivity to market risk”), macroeconómicas, bancário e do ambiente legislativo. Um outro principal objetivo deste trabalho é conseguir reunir as variáveis explicativas com maior poder preditivo de *distress* bancário na Zona Euro.

Neste trabalho serão utilizadas como variáveis explicativas variáveis CAMELS, retiradas de um vasto leque de trabalhos desenvolvidos por diversos autores (Altman et al, 2014; Betz et al, 2014; Maghyereh e Awartani, 2014; Messai e Jouini, 2013; Vilén, 2010, entre outros).

Também foram adicionadas outras variáveis de carácter macroeconómico e bancário. Para um modelo de previsão, para além das variáveis explicativas é necessário ter bem claro a definição das variáveis dependentes utilizadas no estudo.

O que torna este estudo diferente da maioria é o facto de haver duas variáveis dependentes e analisarmos o impacto das variáveis explicativas para cada variável dependente. As variáveis dependentes neste trabalho foram denominadas de: falência (Yfal) e rácio de capital (Ydis). No caso da primeira variável, admitimos que as entidades que se encontram falidas são aquelas que, na base de dados Orbis Bank Focus, se apresentam como: *bankruptcy*, *dissolved* ou *in liquidation* (o banco deixa de existir devido a um processo de liquidação). Em relação à segunda variável, esta é definida pelos níveis mínimos dos rácios de capital propostos pelo Acordo da Basileia III, desta forma, as entidades são consideradas em *distress* sempre que, em algum período, não tenham o *Tier 1 Common Equity Ratio* de pelo menos 4,5%, o *Total Capital Ratio* de pelo menos 8% ou o rácio *Tier 1 Capital* sobre os *Risk-Weighted Assets* de pelo menos 8,5%.

Para amostra foram seleccionados, da base de dados Orbis Bank Focus, 4046 bancos da Zona Euro e cujo código de consolidação seja U1, ou seja, as demonstrações de resultados dessas instituições não integram as demonstrações das empresas subsidiárias ou sucursais controladas. Destas 4046 entidades, 450 estão em *distress* segundo a variável dependente falência (Yfal), já segundo a definição da variável rácio de capital (Ydis), apenas 235 bancos são considerados em *distress*.

Neste estudo será utilizada uma regressão logística para criar um modelo de previsão de *distress* bancário. Este modelo será estimado várias vezes com diferentes conjuntos de dados, nomeadamente com todas as variáveis seleccionadas, apenas com as variáveis CAMELS, e apenas com as outras variáveis, e ainda para diversos horizontes temporais, sendo utilizados dados com defasamentos temporais desde um ano antes do momento de *distress*, até três anos antes, de modo a verificar a significância das variáveis para os diferentes horizontes temporais.

Este trabalho está dividido em três grandes secções: Revisão da literatura, Metodologia e Resultados Empíricos. A primeira secção é onde são abordadas investigações pertinentes de diversos autores que, ao longo dos tempos, contribuíram para o desenvolvimento de trabalhos relacionados com previsão de falências em diversos setores, regiões geográficas e

através das mais diversas metodologias. É ainda reservado um subcapítulo para as várias definições de *bank distress* que foram sendo desenvolvidas ao longo dos tempos. No capítulo da Metodologia são descritas as variáveis dependentes utilizadas no estudo, apresentadas e explicadas as variáveis independentes e os seus sinais esperados, detalhados os dados e a amostra utilizada, temos ainda uma subsecção que se destina a abordar as especificações teóricas dos modelos e, por último, são apresentadas as quatro hipóteses de investigação a sere estudadas. Por último, temos o capítulo dos Resultados Empíricos onde são apresentados e discutidos os resultados da análise discriminante e dos modelos logísticos desenvolvidos.

2. Revisão da literatura

Desde Beaver (1966), um grande número de investigadores tem vindo a desenvolver estudos sobre a previsão de falências. Ao longo desta vasta literatura é possível encontrar várias metodologias e variáveis explicativas aplicadas ao mesmo problema, tentar prever situações de falência. Como variáveis independentes, muitas vezes são utilizados: rácios contabilísticos retirados de demonstrações financeiras, tais como medidas de rentabilidade, liquidez e alavancagem, ou ainda, variáveis de mercado, como a volatilidade dos retornos das ações e as rentabilidades passadas, variáveis macroeconómicas e do ambiente legislativo.

Seguindo as linhas orientadoras deixadas por Beaver, Altman (1968) construiu o modelo de Análise Discriminante Múltipla denominado por Z-score. Para este estudo foi utilizada uma amostra emparelhada de 33 empresas saudáveis e 33 falidas, de grandes dimensões (ativo superior a um milhão de euros), num horizonte temporal estabelecido entre 1946 e 1965. Inicialmente foram analisados 22 rácios financeiros e, após uma análise estatística, apenas restaram 5 rácios estatisticamente significativos: alavancagem ($\frac{EBIT}{Ativo\ Total}$); atividade ($\frac{Vendas}{Ativo\ Total}$); liquidez ($\frac{Fundo\ de\ maneo}{Ativo\ Total}$); rentabilidade ($\frac{Resultados\ Transitados}{Ativo\ Total}$); e solvabilidade ($\frac{EBIT}{Passivo\ Total}$). Este modelo teve uma taxa de sucesso de 95% quando se previu a falência das empresas um ano antes do acontecimento, e de 83% quando passamos a prever dois anos antes. O modelo de Altman foi bem aceite pela comunidade científica e adotada posteriormente por muitos investigadores (Lin, 2010; Kouki & Elkhaldi, 2011 e Jordan, 2010).

O trabalho de Ohlson (1980) foi um dos primeiros a utilizar o modelo logístico em dados *cross-section* para a criação de um modelo de previsão de falência, e tornou-se num dos modelos mais populares até aos dias de hoje. O autor utilizou nove variáveis explicativas e uma amostra não-emparelhada de 2058 empresas saudáveis e 105 insolventes nos EUA. O autor criou três modelos para um ano, dois anos e entre um e dois anos antes da falência. Este estudo permitiu ao investigador concluir que o poder de previsão de qualquer modelo depende do *timing* em que a informação é disponibilizada. Este modelo apresentou uma capacidade preditiva de cerca de 96% tanto um, como dois anos antes da falência. Contudo, a popularidade do modelo de Ohlson não impediu que surgissem críticas, como a de Zavgren

(1985) que pôs em causa o facto de a amostra não ser emparelhada, mas sim com uma diferença significativa entre empresas saudáveis e insolventes.

Wang e Ji (s.d.) chegaram à conclusão que as variáveis significativas na previsão de falências nos bancos dos EUA e Reino Unido, no período pré-crise (2000-2006) diferem das estatisticamente significativas para o período de crise (2007-2012). Neste caso, no período pré-crise as variáveis significativas são: qualidade da gestão, liquidez, risco de crédito e tamanho do banco. Já no período de crise são tidas como mais importantes as variáveis derivadas da gestão.

Thomson (1991) utilizou para sua amostra dados de bancos dos EUA entre 1982 e 1989 e, usando a regressão logística, chegou à conclusão que a liquidez e solvabilidade são as variáveis mais significativas para o modelo de previsão de falência.

Martin (1977) destacou-se por usar, ao contrário da maioria das pesquisas anteriores, uma grande amostra, 5700 bancos, onde 58 foram identificados como falidos, durante um período de 7 anos na década de 70. O autor concluiu que diferentes indicadores de Liquidez, Ganhos e adequação do Capital foram os indicadores mais significativos para a previsão de falência.

Contrariamente a outros estudos, Lennox (1999) defendeu que os modelos *Logit* e *Probit* conseguem ter maior poder preditivo que a Análise Discriminante Múltipla. Esta investigação teve por base uma amostra 949 empresas do Reino Unido, no período de 1987 a 1994. As variáveis que se apresentaram com maior poder preditivo foram: a rentabilidade, dívida, *cash-flow*, dimensão, setor industrial e ciclos económicos. Apesar da análise Probit ser um dos modelos menos utilizados na literatura, alguns autores ainda desenvolveram investigações com este método (Cole e Wu, 2009).

Outro estudo britânico de referência na área foi o de Logan (2001), que aplicou a regressão logística para prever falências de bancos britânicos nos anos 90. O autor concluiu que os indicadores de alavancagem, liquidez, crescimento dos empréstimos, lucro e resultado líquido têm um bom poder preditivo de falência. Também Kuznetsov (2003) adotou uma metodologia parecida a de Logan. Este autor concluiu que os bancos com grande investimento em obrigações do Estado têm maior probabilidade de ultrapassar uma crise e, por outro lado, a rendibilidade e liquidez dos bancos não parecem ter influência na probabilidade de falência bancária.

Kolari et al (2002) analisou empiricamente a eficiência de modelos de previsão de falências em grandes bancos comerciais nos Estados Unidos da América entre os anos 1989 e 1992. Os autores recolheram dados dos diversos bancos de um e dois anos antes da falência e desenvolveram um modelo *logit* e um modelo de *trait recognition*. Ambos os modelos excederam os 95% de capacidade preditiva, mostrando que estes dois modelos têm grande valor para a previsão de falências bancárias.

Männasoo & Mayes (2005) desenvolveram, para uma amostra de bancos da Europa de Leste entre 1996 e 2003, um modelo *logit* com as variáveis CAMELS e fatores estruturais e macroeconómicos. Os autores chegaram à conclusão que os fatores determinantes de falências mudam à medida que uma crise se aproxima, pois os responsáveis pelos bancos e as autoridades bancárias tentam preveni-la. As conclusões destes autores foram apoiadas quando estes utilizaram, num trabalho posterior (Männasoo & Mayes, 2009), uma amostra mais refinada e um horizonte temporal mais alargado, e obtiveram as mesmas conclusões.

Por outro lado, Konstandina (2006) usou o modelo *Logit* para prever a falência de bancos russos. Foram usados 6 indicadores macroeconómicos e 13 variáveis específicas bancárias. Verificou-se que o aumento de “bad debts” e a retenção de bilhetes do Tesouro aumenta o risco de falência bancária.

Uma referência portuguesa na área trata-se do trabalho de Carlos das Neves (2007), onde foi criado um modelo de previsão de falência aplicado à realidade de Portugal. Foram utilizadas 100 empresas solventes e outras 87 que se encontravam em incumprimento. O autor selecionou 70 rácios financeiros e combinou-os através do modelo logístico, mas também com as linhas do modelo Z-Score. Este modelo apresentou uma capacidade preditiva na ordem dos 81%.

Mais recentemente, Jordan et al (2010) analisaram 225 bancos que faliram entre 2 de fevereiro de 2007 e 23 de abril de 2010, comparando-os com outros que não faliram até 23 de abril de 2010. Os dados foram retirados do *website* da Federal Deposit Insurance Corporation (FDIC). Foi efetuada uma análise de regressão ANOVA e, posteriormente, a amostra foi dividida aleatoriamente em dois grupos: o *training group* e *testing group*. Foi conduzido uma Análise Discriminante Múltipla na *training group* desde um trimestre antes da falência até quatro anos, e depois foi testada a análise discriminante usando o grupo de teste. Em relação aos resultados da regressão ANOVA, verificamos que as variáveis explicativas:

$\frac{\text{Non accrual asset} + \text{Owned real estate}}{\text{Total Assets}}$, $\frac{\text{Real estate loans}}{\text{Total assets}}$, $\frac{\text{Interest income}}{\text{Earning assets}}$, e a variável *dummy* MSA, têm coeficientes positivos e estatisticamente significantes. Já as variáveis $\frac{\text{Tier One Capital}}{\text{Total Assets}}$ e a *dummy* Savings Bank apresentam coeficientes negativos. O modelo de Análise Discriminante Múltipla previu corretamente 66% dos bancos falidos, 4 anos antes da falência e 88,2%, um ano antes da falência, tendo uma taxa média de sucesso de 76,8%.

O trabalho de Messai e Jouini (2013) conta com uma amostra de 368 bancos comerciais de grande dimensão de 8 países europeus no período compreendido entre 2004 e 2007. Os dados utilizados são provenientes de demonstrações financeiras dos bancos, retiradas da base de dados BankScope (atualmente descontinuada). Numa primeira fase, o modelo foi construído tendo em conta apenas os rácios que constituem o sistema de *rating* CAMEL. Numa fase posterior, foram acrescentadas variáveis relacionadas com o ambiente legislativo. Os autores para testarem o modelo realizaram três procedimentos: determinação da correlação entre a variável dependente e os diferentes rácios; regressão *logit* com as variáveis CAMEL; e regressão *logit* com as variáveis CAMEL e os fatores do ambiente legislativo. A nível de resultados verifica-se que a taxa de cobertura dos empréstimos pelo Capital Próprio, as *proxies* da qualidade da gestão e da rentabilidade estão inversamente relacionados com a probabilidade de falência, já os rácios *proxies* da qualidade afetam positivamente a variável dependente.

Um dos estudos que serviu de base para esta investigação foi o de Betz et al (2014). Este estudo contou com uma amostra de 546 bancos com observações entre o primeiro trimestre de 2000 e o segundo trimestre de 2013. Os dados necessários foram retirados das bases de dados Bloomberg e Bankscope. A nível de variáveis explicativas, para além de serem usados os indicadores CAMELS, foram ainda utilizados indicadores bancários e financeiros específicos de cada país. Foi adotado um modelo *logit*, para proceder à previsão de *distress* em cada trimestre, e foram criados seis modelos com diferentes conjuntos de variáveis explicativas: (i) com todas as variáveis, (ii) só com as variáveis CAMELS, (iii) só com as variáveis específicas do setor bancário, (iv) só com as variáveis específicas do país, (v) com as variáveis CAMELS e as específicas do setor e (vi) com as variáveis CAMELS e as específicas do país. Verificou-se que os indicadores específicos do país têm maior utilidade do que os indicadores bancários em prever falência, contudo o modelo com todos os indicadores em estudo é o que apresenta maior poder preditivo.

Alguns estudos tiveram como propósito fazer comparações entre vários modelos de previsão de falências, com diferentes variáveis independentes e diferentes modelos econométricos. O trabalho de Wu et al (2010) foi um dos casos anteriores. Foram estudados e comparados os modelos de Análise Múltipla Discriminante de Altman (1968), modelo *Logit* de Ohlson (1980), modelo *Probit* de Zmijewski (1984), modelo *Hazard* de Shumway (2001) e modelo *Black-Scholes option-pricing* de Hillegeist et al. (2004). Os autores chegaram à conclusão que as entidades com maior probabilidade de falência têm: menor rácio de Resultados antes de Impostos e Encargos Financeiros sobre Ativo Total, grande diminuição do Resultado Líquido, baixo rácio de *working capital* sobre Ativo Total. Uma outra conclusão a que chegaram foi que os modelos com informação financeira, de mercado e de setor de mercado são os que melhor performance têm.

2.1. Definição de *bank distress*

Não existe ao longo de toda a literatura uma definição única de *bank distress*, sendo utilizadas diferentes definições por vários autores. Contudo, Watson e Everett (1993) afirmam na sua investigação que o termo falência deve estar explicitamente definido no estudo, na medida em que a própria variável dependente do estudo pode variar em grande medida dependendo da definição adotada pelo investigador.

Martin (1977) diz-nos que um banco entra em falência quando o seu valor líquido se torna negativo, ou quando não é possível continuar com as suas operações sem incorrer em perdas que podem levar a resultados negativos.

O estudo de Carapeto et al (2010) mostra-nos que na realidade existe uma imensidão de definições para o fenómeno de *bank distress* pois este apresenta 11 diferentes medidas *proxies*. Altman (1993) distinguiu quatro termos muito utilizados e confundidos: *bankruptcy*, *insolvency*, *default* e *failure*. E de uma forma mais genérica, Oluwakayode (2017) defendeu que um banco em *distress* é aquele que não tem capacidade financeira de pagar aos seus clientes ou depositantes.

Os fenómenos de falência bancária na Europa são muito raros, o que levou Betz et al (2013) a considerarem, para além de situações de falência e liquidações, também situações de ajuda governamental e fusões forçadas, de modo a obter uma amostra mais abrangente e significativa.

Segundo Altman et al (2014), *bank distress* é uma condição onde o rendimento esperado ou realizado de um banco, através dos seus ativos, se deteriora de modo a comprometer a capacidade do banco honrar os seus compromissos com os credores. E, seguindo a definição deste autor, podem existir dois tipos de resolução para bancos em situação de *distress*: *bank closures* e *open-bank resolutions*. No primeiro caso, os bancos deixam de existir como entidades independentes, incluem-se aqui as liquidações, falências, fusões por mau desempenho de um banco. Já no segundo caso, os bancos continuam a operar mas com assistência governamental.

Para Maghyereh et al (2014), um banco em *distress* é definido como estando numa das seguintes situações: (a) as operações dos bancos estão temporariamente suspensas; (b) a instituição bancária foi recapitalizada ou recebeu alguma ajuda de liquidez por parte de uma

autoridade bancária; (c) o banco fundiu-se com outro devido a *distress* financeiro; (d) o banco encerrou as suas atividades por ordem governamental; (e) o rácio de dívida de cobrança duvidosa sobre o total de empréstimos concedidos, durante dois anos consecutivos, esteja no quarto quartil da distribuição da amostra.

Khaddafi et al (2017) deram uma nova vertente ao trabalho desenvolvido por Altman (2000) e assumiram que um Z-score superior a 2.99 representava bancos muito saudáveis, os valores compreendidos entre 1.81 e 2.99 estavam na “zona cinzenta”, onde o futuro da instituição dependia do desempenho da gestão. Já os valores de Z-score inferior a 1.81 eram indicadores de bancos em grandes dificuldades financeiras.

De acordo com o acordo da Basileia III (Basel III), todos os bancos devem ter uma determinada quantidade de capital que os permita fazer face a potenciais perdas. Segundo este acordo o *Tier 1 Common Equity Ratio* deve ser de pelo menos 4,5%, o *Total Capital Ratio* deve ser de pelo menos 8%, e por fim o *Tier 1 Capital* deve representar pelo menos 8,5% dos *Risk-Weighted Assets*. Já nos Estados Unidos da América, o *Federal Deposit Insurance Corporation* (FDIC) incluiu também uma medida *proxy* do *Tier 1 Capital Ratio*, que consiste no rácio *Total Equity Capital* subtraído do *Goodwill*, dividido pelo total do Ativo, onde um banco que apresente este rácio abaixo dos 2% é considerado em *distress* e os reguladores são obrigados a intervir (Carapeto et al, 2010).

3. Metodologia

Nesta secção será abordada toda a informação metodológica para que seja possível definir e entender o modelo criado. É dado a conhecer as fontes de informação que levaram à formação das variáveis, as suas definições e as metodologias aplicadas, e por fim, são formuladas as hipóteses de investigação para este trabalho.

3.1. Variáveis Utilizadas

Quanto às variáveis explicativas ou independentes, não existe um consenso ao longo da literatura sobre as melhores variáveis, aquelas com maior poder preditivo. Na realidade, existe um vasto leque de variáveis explicativas que nos permitem analisar a saúde financeira dos bancos.

De acordo com Andersen (2008), as agências federais bancárias, motivadas pela consistência de padrão na insolvência bancária, adotaram um sistema de *rating* denominado por CAMEL (C- “Capital adequacy”, A- “Asset quality”, M- “Management competence”, E- “Earnings”, L- “Liquidity”, e em 1997 foi adotado um sexto componente: S- “Sensitivity to market risk”, passando a se denominar por CAMELS).

As variáveis explicativas foram selecionadas a partir de uma vasta literatura existente sobre o tema, sendo estas um conjunto de variáveis CAMELS e não-CAMELS. Na escolha das variáveis há que ter em conta que não existe uma única forma de conjugar as diferentes variáveis, como também não há um conjunto de variáveis que prevejam, sem erro, as falências bancárias.

A categoria Capital Adequacy é importante para medir a saúde bancária. O capital dos bancos serve para cobrir perdas e investimentos. A Qualidade dos Ativos consegue captar problemas financeiros e fragilidade bancária, pois um banco que mantenha ativos de qualidade inferior é mais vulnerável a perdas. A Competência da Gestão trata-se da capacidade do órgão de gestão do banco em manter a instituição com uma boa performance, assim quanto melhor a competência do órgão de gestão, menor será a vulnerabilidade do banco. Earning Ability é uma categoria deste sistema que reflete a capacidade do banco em criar lucros. Um banco com maior rentabilidade deve ter uma performance económica e financeira superior, o que em geral nos leva a criar uma relação inversa entre esta categoria e a probabilidade de falência.

Os rácios que fazem parte da categoria de Liquidez medem a capacidade do banco em cumprir as suas obrigações de curto-prazo. Por norma, a liquidez está negativamente correlacionada com a probabilidade de falência. Mas, apesar de a liquidez ser um facto positivo não pode ser em excesso pois o banco pode perder rentabilidade pelo capital parado que poderia estar a ser investido. Por último, a Sensibilidade ao risco de mercado mede o impacto que flutuações no mercado financeiro podem ter nos bancos. Os bancos podem ser muito vulneráveis às flutuações de mercado principalmente se dependerem fortemente do mercado para refinanciamento.

Na Tabela 1 são apresentadas as variáveis CAMELS seleccionadas para utilização neste estudo.

Os estudos iniciais que utilizavam o sistema CAMEL focavam-se essencialmente em indicadores contabilístico-financeiros, mas estes modelos apresentavam alguns limites em prever falências bancárias, pelo que alguns autores adicionaram outras variáveis para complementar a análise, como por exemplo: variáveis macroeconómicas, que capturam choques e diferenças económicas de modo a conseguir captar indicações de falências bancárias ou divergências em estudos *cross-countries* (Rojas-Suarez, 2001); ou dados de mercado (Flannery, 1998), embora apenas se possam utilizar para entidades com informação de mercado pública.

As variáveis CAMELS por si mesmas podem não ser suficientes para explicar a probabilidade de falência dos bancos da zona euro, por isso foram incluídas também no estudo variáveis não-CAMELS. Nas variáveis não-CAMELS estão incluídos indicadores macroeconómicos que podem ter um grande impacto na economia como um todo, mas também em cada banco individualmente. Na Tabela 2 encontram-se descritas as variáveis não-CAMELS utilizadas no estudo.

Na Zona Euro não existem muitos casos de falências no setor bancário, devido também à existência de diversos mecanismos de segurança impostos pelo Banco Central Europeu e até pela União Europeia, tais como Mecanismo Único de Supervisão (MUS) e o Mecanismo Único de Resolução (MUR). Desta forma, um estudo sobre a falência bancária na Zona Euro podia levar a um baixo número de bancos na amostra, assim foi considerado, como em muitos estudos na área, utilizar variáveis *proxies* de *distress* bancário, em vez de falência propriamente dita. Como variável dependente foram utilizadas duas diferentes ao longo do

trabalho, com o objetivo de se verificar se as variáveis explicativas têm o mesmo poder preditivo para as diferentes variáveis dependentes. Para a primeira variável, denominada por falência (Yfal), admitimos que as entidades que se encontram falidas são aquelas que, na base de dados Orbis Bank Focus, se apresentam como: *bankruptcy* (a empresa já não existe pois cessou as suas atividades devido a um processo de insolvência), *dissolved* (já não existe como uma entidade legal), ou *in liquidation* (o banco deixa de existir devido a um processo de liquidação). A segunda variável, denominada no trabalho por rácio de capital (Ydis), é uma interpretação do Acordo da Basileia III e dos seus níveis mínimos de rácios de capital propostos, como explicado na secção anterior. Assim, os bancos que em algum período não tenham o Tier 1 *Common Equity Ratio* de pelo menos 4,5%, o Total Capital Ratio de pelo menos 8% ou o rácio *Tier 1 Capital* sobre os *Risk-Weighted Assets* de pelo menos 8,5%, serão considerados em *distress*.

Tabela 1- Descrição e sinal esperado das variáveis CAMELS

Variáveis CAMELS	Descrição	Sinal Esperado	Literatura Relacionada	Breve descrição	
C	Eq_TotAt	Capital Próprio sobre Ativo Total	-	Betz et al (2014), Messai e Jouini (2013), Poghosyan e Cihák (2011), Wang e Ji (s.d.)	Indica a capacidade dos bancos em satisfazer as suas obrigações, absorvendo possíveis perdas e choques financeiros.
C	Eq_NetLoan	Capital Próprio sobre Empréstimos Líquidos concedidos	-	Altman et al (2014), Messai et al (2013), Vilén (2010)	Mede o nível de proteção baseado em investimentos de capital próprio contra perdas em empréstimos concedidos.
C	Tier1	Rácio Tier 1	-	Betz et al (2014), Altman et al (2014), Maghyereh et al (2014)	
A	NetLoan_TotAt	Empréstimos Líquidos concedidos sobre Ativo Total	+	Maghyereh et al (2014), Messai e Jouini (2013), Vilén (2010), Kolari et al (2002)	Indica a percentagem de ativos que são empréstimos concedidos.
A	OthOpInc_AvgAt	Outros Rendimentos Operacionais sobre Média de Ativo	+	Messai e Jouini (2013)	Mede a parte de rendimento gerado por outras atividades fora do core da atividade da entidade.
A	LoanLRes_GrLoan	Reserva para perdas em Empréstimos concedidos sobre Empréstimos Brutos	+	Betz et al (2014), Altman et al (2014), Maghyereh et al (2014), Vilén (2010)	Percentagem dos empréstimos concedidos que esta coberto.
M	CostToInc	Rácio Cost to Income	+	Betz et al (2014), Altman et al (2014)	

(Continuação da Tabela 1)

M	OpInc_At	Rendimento Operacional sobre Ativo Total	-	Messai e Jouini (2013)	
E	ROAA	Return on Average Assets – Rentabilidade operacional da média dos ativos	-	Altman et al (2014), Maghyereh et al (2014), Vilén (2010)	Mede a eficiência e performance operacional.
E	ROAE	Return on Average Equity – Rentabilidade operacional da média do Capital Próprio	+/-	Altman et al (2014), Maghyereh et al (2014), Messai e Jouini (2013)	Mede o retorno dos fundos dos investidores.
E	NetIntMargin	Margem de juros Líquida	-	Betz et al (2014), Vilén (2010)	Mede o resultado líquido de juros relativamente aos ativos rentáveis.
E	IntExp_Liab	Despesas em juros sobre Passivo Total	+	Betz et al (2014)	
L	DepShTFund_At	Depósitos e fundos de curto-prazo sobre Ativo Total	+/-	Messai e Jouini (2013), Vilén (2010), Wang e Ji (s.d.)	Os depósitos e fundos de curto- prazo são medidos como percentagem do total de ativos.
L	DepShTFund_Liab	Depósitos e fundos de curto-prazo sobre Passivo Total	+/-	Messai e Jouini (2012)	
L	Loan_Liab	Total de empréstimos concedidos sobre o Passivo total	-	Wang e Ji (s.d.)	
L	Loan_DepShTFund	Empréstimos concedidos sobre Depósitos e fundos de curto-prazo	+/-	Betz et al (2014), Vilén (2010)	Mede a quantidade de empréstimos concedidos em comparação com os depósitos e fundos de curto-prazo.
S	TradRev_OpRev	Rendimento de <i>trading</i> sobre rendimento operacional	+	Betz et al (2014)	

Tabela 2 - *Descrição e sinal esperado das Variáveis Não-CAMELS*

Variáveis Não-CAMELS	Descrição	Sinal Esperado	Literatura Relacionada
GDPRealGrow	Crescimento Real do PIB	-	Maghyereh et al (2014),
Inflation	Taxa de inflação	+	Maghyereh et al (2014),
TotAtGrow	Taxa de crescimento do Ativo	-	Wang e Ji (s.d)
LoanGrow	Taxa de crescimento dos empréstimos concedidos	-	Vilén (2010), Wang e Ji (s.d)
LnAsset	Logaritmo natural do Ativo	+/-	Maghyereh et al (2014), Ploeg (2010), Vilén (2010), Wang e Ji (s.d)
Crise	Variável Dummy que indica se o país a que pertence o banco entrou ou não numa crise económica. Se pertencer a Portugal, Espanha, Itália, Grécia, Chipre ou Irlanda assume valor igual a 1, caso contrário assume valor 0.	+	

3.2. Dados e amostra

A base de dados utilizada para este estudo foi a Orbis Bank Focus da Bureau van Dijk, de onde todas as variáveis independentes foram retiradas e de onde foi possível construir as duas variáveis dependentes. Foram selecionados apenas os bancos da Zona Euro, de modo a não haver perda de informação devido a diferenças cambiais, e cujas demonstrações de resultados não integrem as demonstrações das empresas subsidiárias ou sucursais controladas pelo banco, ou seja, apenas foram selecionados os bancos com código de consolidação U1. Assim, obteve-se uma amostra de 4046 bancos.

Os dados foram recolhidos numa lógica anual entre 2012 a 2017, o que criou 24276 observações. Dos 4046 bancos, 450 entraram em *distress* entre 2012 e 2017, segundo a primeira definição de *distress* utilizada (Yfal), ou seja, 450 bancos encontram-se em *distress* devido a situações de: falência, liquidação ou dissolução devido a um processo de fusão. Mas, segundo a outra definição de *distress* utilizada neste estudo (Ydis), existem 235 bancos em *distress*, ou seja, não cumprem pelo menos um dos requisitos mínimos dos rácios de Capital propostos pelo Acordo da Basileia III.

Na Tabela 3 podemos verificar o número de bancos em *distress*, segundo a variável dependente falência (Yfal), em cada ano, e na Tabela 4 os bancos em *distress* seguindo a definição interpretada no acordo da Basileia III.

Tabela 3- Bancos em distress, por ano (variável falência, Yfal)

2012	44
2013	45
2014	50
2015	84
2016	167
2017	60
Total	450

Tabela 4- Bancos em distress, por ano (variável rácio de capital, Ydis)

2012	17
2013	90
2014	47
2015	36
2016	35
2017	10
Total	235

3.3. Especificações do modelo

O objetivo central deste estudo é identificar os indicadores que melhor conseguem prever a falência bancária na Zona Euro. Uma abordagem utilizada em muitos estudos e que pode ser denominada de *ex post empirical*, ou seja, onde um grupo de entidades falidas é identificado e as características desses bancos de um ou mais anos são comparadas com um grupo de bancos saudáveis no mesmo período (Martin, 1977).

O modelo *logit* é um dos modelos que foi muito utilizado ao longo da literatura na previsão de falência. Este modelo não age de forma normalizada para todas as variáveis independentes, o que, neste caso, é benéfico na medida em que os dados bancários não costumam ser normalmente distribuídos (Vilén, 2010; Kolari et al, 2002).

A utilização do modelo *logit* implica que assumamos que a variável dependente seja binária (*dummy*), ou seja, que o seu valor seja 1 para bancos em *distress*, e a 0 para bancos saudáveis. As variáveis dependentes consistem nas diferentes variáveis CAMELS e não-CAMELS que foram expostas no Capítulo 3.1.

A regressão logística pode-se traduzir na seguinte forma:

$$F(x) = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_k X_{ki} \quad (3.1)$$

Onde $\beta = \beta_1, \dots, \beta_k$ são os vetores dos coeficientes das variáveis independentes X_i ($i=1, \dots, k$).

E podemos definir que a probabilidade de um banco falir (dado por $Y=1$) como uma função de distribuição logística, através da Equação (3.2):

$$\text{Prob}(Y_i = 1) = \frac{1}{1+e^{-F(x)}} \quad (3.2)$$

Já a probabilidade de um banco não falir é dada pela seguinte Equação (3.3):

$$\text{Prob}(Y_i = 0) = 1 - \frac{1}{1+e^{-F(x)}} \quad (3.3)$$

Com este tipo de modelo é possível gerar probabilidades de falências que permitem sinalizar certos bancos que necessitam de ser analisados detalhadamente e tidos em atenção, de modo a poder prevenir ou minimizar as suas dificuldades (Andersen, 2008).

Muitas vezes os bancos que estão a passar por problemas tendem a escondê-los, pelo que se torna muito complicado detetar sinais de problemas ao apenas analisar as demonstrações financeiras das instituições (Demirgüç-Kunt, 1989).

O modelo logístico gera estimativas de coeficientes e, associado a estes, testes estatísticos que indicam a sua significância. Mas existem algumas limitações, como o facto de não ser possível saber qual a capacidade das variáveis em reduzir os erros de tipo I (percentagem de bancos em *distress* classificados como saudáveis) ou de tipo II (percentagem de bancos saudáveis considerados como em *distress*) (Kolari et al, 2002).

Neste estudo será utilizada a regressão logística utilizando duas variáveis dependentes diferentes, como abordado da secção anterior. Para cada uma destas variáveis dependentes serão utilizados dados de um (lag1), dois (lag2) e três (lag3) anos antes do momento de *distress*. Para além dos diferentes horizontes temporais, também será estudado o impacto de diferentes conjuntos de variáveis explicativas, sendo criados modelos com todas as variáveis, e modelos parciais apenas com as variáveis CAMELS ou com as outras variáveis. Assim perfazendo um total de 18 modelos de previsão. Para todos estes modelos foi adotado o processo de correção de Huber-White devido à probabilidade de existência de heterocedasticidade.

3.4. Hipóteses de investigação

O principal objetivo desta análise é contruir um modelo de previsão de *distress* que tenha um grande poder preditivo. Para isso, as variáveis explicativas necessitam de ser significativas, pois os bancos em *distress* devem apresentar características diferentes dos bancos saudáveis. Desta forma é imprescindível estudarmos as seguintes hipóteses:

H1: Um banco inserido num país que esteja a passar ou já tenha passado uma crise financeira aumenta a sua probabilidade de *distress*.

Uma crise financeira pode assolar muitos setores numa economia, e neste caso o objetivo é saber se isso também se aplica ao setor bancário.

H2: As variáveis CAMELS têm influência sobre a probabilidade de *distress* bancário.

De acordo com a literatura existente sobre o tema, os indicadores CAMELS apresentam influência na probabilidade de *distress*. Desta forma, pretende-se verificar se os resultados desta investigação vai de encontro com a literatura relacionada.

H3: Os modelos com as variáveis CAMELS e não-CAMELS têm maior poder preditivo de *bank distress*.

Ao longo da literatura vários autores defenderam que os modelos com variáveis CAMELS e não-CAMELS, como macroeconómicas e bancárias, tinham maior poder preditivo do que os modelos com apenas um dos tipos de variáveis.

H4: Os resultados dos modelos obtidos com diferentes variáveis *proxies* de *bank distress* podem não ser os mesmos.

Watson e Everett (1993) explicaram no seu trabalho que as variáveis dependentes devem ser bem definidas logo de partida pois podem influenciar em grande medida os resultados obtidos.

4. Resultados Empíricos

4.1. Análise da Estatística Descritiva

O principal objetivo da Estatística Descritiva é analisar de forma isolada cada variável explicativa. Neste estudo, temos dois tipos de bancos: bancos saudáveis ($Y=0$) e bancos em *distress* ($Y=1$). Desta maneira fez-se a Estatística Descritiva tendo em consideração esta diferença, apresentando as estatísticas para bancos saudáveis e para bancos em *distress*, de modo a captar as possíveis diferenças entre os dois grupos. A estatística descritiva das variáveis explicativas, tendo em consideração que a variável explicada é a primeira considerada (Y_{fal}) é apresentada na Tabela 5, já para a segunda variável (Y_{dis}) é apresentada na Tabela 6.

Tabela 5- *Estatística Descritivas das variáveis explicativas, considerando a variável dependente falência (Y_{fal})*

Variável	Média		Mediana		Desvio-Padrão	
	Y=1	Y=0	Y=1	Y=0	Y=1	Y=0
Eq_TotAt	13.5273	13.7370	8.814	9.3065	18.7264	19.2654
Eq_NetLoan	29.7226	34.1245	14.7990	15.9320	60.5488	85.8346
Tier1	13.9620	18.6568	14.9650	14.8000	5.3792	21.8295
NetLoan_TotAt	57.7148	55.5159	60.9890	58.9450	19.3274	22.0909
OthOpInc_AvgAt	1.6516	5.2651	1.0970	0.9880	1.7277	21.9495
LoanLRes_GrLoan	5.4518	3.9654	3.7410	1.6015	5.2051	8.8969
CostToInc	80.7641	76.4942	79.1325	76.1480	25.3542	36.7329
OpInc_Asset	0.0521	0.1077	0.0301	0.0296	0.1047	1.4099
ROAA	-0.1223	0.7592	0.1340	0.2850	0.8667	5.7475
ROAE	-3.9073	4.5175	1.5700	3.1060	17.1731	21.6100
NetIntMargin	1.5555	1.8829	1.9960	1.9820	4.2513	10.4344
IntExp_Liab	0.0085	0.0185	0.0061	0.0081	0.0062	0.3723
DepShTFund_At	0.8337	0.8131	0.7382	0.8695	0.5414	1.3524
DepShTFund_Liab	0.7822	0.8876	0.7601	0.9744	0.2185	0.2024
Loan_Liab	0.5506	0.7703	0.5926	0.6592	0.2648	4.3242
Loan_DepShTFund	0.7382	11.7054	0.7794	0.7066	0.3244	719.1749
TradRev_OpRev	2.4934	5.0221	0.3810	0.2280	7.9386	35.7476
GDPGrow	1.0054	1.2417	1.0750	1.4190	1.0341	1.5514
Inflation	0.6123	0.7213	0.3670	0.6950	0.6020	0.6738
TotAtGrow	6.4998	5.9611	0.2080	3.2600	37.2819	28.0372
LoanGrow	6.0147	7.6422	-2.3620	3.3800	53.7356	43.8285
LnAsset	12.7586	13.0059	12.6444	12.9646	1.7129	1.9000
Crise	0.4156	0.2042	0.0000	0.0000	0.4934	0.4031

Tabela 6- *Estatística Descritivas das variáveis explicativas, considerando a variável dependente rácio de capital (Ydis)*

Variável	Média		Mediana		Desvio-Padrão	
	Y=1	Y=0	Y=1	Y=0	Y=1	Y=0
Eq_TotAt	6.3916	13.7180	5.5400	9.3050	6.6929	19.1303
Eq_NetLoan	14.5158	33.7625	8.3695	15.8890	41.1436	84.9353
Tier1	6.8903	18.8057	7.5770	14.8900	2.0796	22.2456
NetLoan_TotAt	64.1735	55.6326	62.8490	59.0510	18.8606	22.0056
OthOpInc_AvgAt	2.3371	5.1123	0.9625	0.9910	9.1446	21.5189
LoanLossRes_GrLoan	8.0226	4.0652	4.6290	1.6700	12.1456	8.7511
CostToInc	78.7713	76.5465	78.0810	76.0090	27.9948	37.9186
OpInc_Asset	0.0424	0.1043	0.0298	0.0297	0.0968	1.3714
ROAA	-0.7208	0.7178	0.1310	0.2790	4.3669	5.6283
ROAE	-12.5655	4.2377	1.9615	3.0580	52.3400	21.2220
NetIntMargin	2.0344	1.8860	2.0450	1.9860	0.9423	10.1453
IntExp_Liabilities	0.0130	0.0194	0.0120	0.0082	0.0069	0.3724
DepShTFund_Asset	0.8007	0.8096	0.8648	0.8679	0.1989	1.3164
DepShTFund_Liabilities	0.8519	0.8843	0.9473	0.9741	0.1897	0.2026
Loan_Liabilities	0.6719	1.2431	0.6674	0.6605	0.2064	48.2116
Loan_DepShTFund	5.3413	12.6890	0.7642	0.7113	66.6065	721.9019
TradRev_OpRev	2.3926	4.6195	0.2540	0.2410	7.4494	34.3806
GDPGrow	0.5813	1.1936	0.6000	1.1240	1.1144	1.5129
Inflation	0.8105	0.7307	0.7740	0.774	0.6514	0.6770
TotAtGrow	3.8563	5.6758	2.5840	3.1405	16.1123	27.7584
LoanGrow	3.4455	7.2735	1.8795	3.1840	19.3804	43.6061
LnAsset	13.4522	12.9747	13.2543	12.9335	1.6250	1.8891
Crise	0.5659	0.2218	1	0	0.4967	0.4155

As tabelas mostram que existe uma maior diferença entre os valores dos bancos em *distress* e dos bancos saudáveis na Tabela 6, quando se tem em consideração a variável dependente rácio de capital (Ydis). Já os valores das duas categorias de bancos apresentados na Tabela 5 encontram-se mais próximos entre si. As variáveis de *Capital Adequacy* apresentam, em média, valores mais elevados para bancos saudáveis do que para bancos em *distress*, o que vai de encontro com o esperado, pois é expectável que estas variáveis tenham um coeficiente negativo na previsão de eventos de *distress*. Na categoria de *Management Quality* verificamos também o previsto, em que a primeira variável (CostToInc) apresenta uma média maior para a categoria Y=1, e pelo contrário a segunda (OpInc_Asset) apresenta, em média, maior valor para Y=0. Também verificamos que as variáveis não-CAMELS também vão de encontro com o esperado.

Assim, para fazer uma análise mais aprofundada da importância das variáveis explicativas iremos fazer uma Análise Multivariada, que é o objetivo da próxima seção.

4.2. Aplicação do modelo

Como foi abordado na secção “Especificações do Modelo”, serão desenvolvidos e apresentados 18 modelos de previsão de eventos de *distress* bancário na Zona Euro, tendo em conta duas diferentes variáveis dependentes, falência (Yfal) e rácio de capital (Ydis). Serão elaborados modelos com todas as variáveis (I), apenas com as variáveis CAMELS (II) e outros apenas com as variáveis não-CAMELS (III), que serão representadas pelas equações (4.1), (4.2) e (4.3), respetivamente. Isto se repetindo com dados de um (lag1), dois (lag2) e três (lag3) anos antes do evento de *distress* bancário.

$$\begin{aligned}
 F(x) = & \beta_0 + \beta_1 Eq_TotAt_i + \beta_2 Eq_NetLoan_i + \beta_3 Tier1_i + \beta_4 NetLoan_TotAt_i \\
 & + \beta_5 OthOpInc_AvgAt_i + \beta_6 LoanLossRes_GrLoan_i + \beta_7 CostToInc_i \\
 & + \beta_8 OpInc_Asset_i + \beta_9 ROAA_i + \beta_{10} ROAE_i + \beta_{11} NetIntMargin_i \\
 & + \beta_{12} IntExp_Liab_i + \beta_{13} DepShTFund_At_i + \beta_{14} DepShTFund_Liab_i \\
 & + \beta_{15} Loan_Liab_i + \beta_{16} Loan_DepShTFund_i + \beta_{17} TradRev_OpRev_i \\
 & + \beta_{18} GDPGrow_i + \beta_{19} Inflation_i + \beta_{20} TotAtGrow_i + \beta_{21} LoanGrow_i \\
 & + \beta_{22} LnAsset_i + \beta_{23} Crise_i
 \end{aligned} \tag{4.1}$$

$$\begin{aligned}
 F(x) = & \beta_0 + \beta_1 Eq_TotAt_i + \beta_2 Eq_NetLoan_i + \beta_3 Tier1_i + \beta_4 NetLoan_TotAt_i \\
 & + \beta_5 OthOpInc_AvgAt_i + \beta_6 LoanLossRes_GrLoan_i + \beta_7 CostToInc_i \\
 & + \beta_8 OpInc_Asset_i + \beta_9 ROAA_i + \beta_{10} ROAE_i + \beta_{11} NetIntMargin_i \\
 & + \beta_{12} IntExp_Liab_i + \beta_{13} DepShTFund_At_i + \beta_{14} DepShTFund_Liab_i \\
 & + \beta_{15} Loan_Liab_i + \beta_{16} Loan_DepShTFund_i + \beta_{17} TradRev_OpRev_i
 \end{aligned} \tag{4.2}$$

$$\begin{aligned}
 F(x) = & \beta_0 + \beta_1 GDPGrow_i + \beta_2 Inflation_i + \beta_3 TotAtGrow_i + \beta_4 LoanGrow_i + \beta_5 LnAsset_i \\
 & + \beta_6 Crise_i
 \end{aligned} \tag{4.3}$$

Primeiramente, na Tabela 7 estão representados 9 modelos cuja variável dependente é falência (Yfal), com os diferentes conjuntos de variáveis e desfasamentos temporais.

Tabela 7- Resultados dos Modelos Logit - variável dependente falência (Yfal)

Variável	Lag1			Lag2			Lag3		
	I.1	II.1	III.1	I.2	II.2	III.2	I.3	II.3	III.3
C	4.7648 (3.5332)	-1.2139 (1.1465)	-1.8500*** (0.4917)	7.7166 (3.6744)	-0.7645 (1.3017)	-1.3355** (0.4629)	3.1569 (3.1117)	0.2045 (1.5616)	-3.9816*** (0.5419)
Eq_TotAt	0.0129 (0.0572)	0.0218 (0.0320)		-0.1552 (0.0627)	-0.1428*** (0.05289)		-0.1625* (0.0917)	-0.1660** (0.0830)	
Eq_NetLoan	-0.0821** (0.0348)	-0.0457 (0.0321)		-0.0025 (0.0051)	-5.26E-05 (0.0065)		0.0081* (0.0049)	0.0073** (0.0037)	
Tier1	0.0132 (0.0116)	0.0111 (0.0112)		0.0041 (0.0189)	0.0192* (0.0115)		0.0233 (0.0160)	0.0192 (0.0151)	
NetLoan_TotAt	0.0346 (0.0396)	-0.0314 (0.0265)		0.0486 (0.0388)	0.0396 (0.0115)		0.0182 (0.1225)	-0.0311 (0.0940)	
OthOpInc_AvgAt	0.7599* (0.4413)	-0.2102 (0.3148)		-0.0276 (0.3699)	-0.1908 (0.2302)		-0.5654 (0.4834)	-0.5389 (0.3529)	
LoanLRes_GrLoan	0.0544 (0.0373)	0.0947*** (0.0222)		0.0842*** (0.3699)	0.0572*** (0.0220)		0.0601* (0.0321)	0.0754*** (0.0220)	
CostToInc	-0.0067 (0.0047)	-0.0025 (0.0020)		-0.0005 (0.0034)	0.0012 (0.0031)		0.0044* (0.0026)	0.0035 (0.0022)	
OpInc_Asset	-53.0663 (45.3015)	24.9652 (20.2356)		13.9167 (30.0556)	35.398* (19.6089)		55.8692 (41.5977)	57.3488* (32.6687)	
ROAE	-0.0030 (0.0163)	-0.0137 (0.0133)		0.0414** (0.0201)	-0.0018 (0.0098)		0.0240 (0.0156)	0.0168 (0.0129)	
ROAA	-0.1675 (0.2387)	-0.2207 (0.1544)		-0.6419** (0.2665)	-0.2944* (0.1644)		-0.7792*** (0.2112)	-0.7029*** (0.1883)	
NetIntMargin	0.8568** (0.4142)	-0.0054 (-0.0054)		0.1759 (0.4016)	0.1209 (0.2540)		-0.0869 (0.4635)	-0.1881 (0.3242)	
IntExp_Liab	-93.1417 (62.6961)	-55.2615 (43.1425)		-73.7289** (32.8644)	-17.7646 (23.3393)		-73.5525** (35.4867)	-62.6771** (28.9135)	
DepShtFund_At	-0.6164 (3.9760)	-2.3644 (2.3881)		-0.0470 (1.9879)	-1.5725* (0.9316)		-0.3053 (2.3527)	-2.6498* (1.5063)	
DepShtFund_Liab	-3.1480 (5.0149)	-2.3775 (2.3881)		-8.3526** (3.5045)	-3.8780* (0.9316)		-5.5415 (3.7922)	-2.7770 (2.2138)	
Loan_Liab	-2.0947 (4.1856)	4.6314** (2.2673)		2.5838 (4.1500)	-0.2483 (3.6352)		2.5601 (11.3881)	6.7576 (8.7509)	
Loan_DepShTFund	-0.2766 (1.4465)	-0.1847 (0.3481)		-3.0279 (1.9955)	-1.0131 (0.8746)		-1.5917 (1.3562)	-1.2984 (1.0423)	
TradRev_OpRev	-0.0034 (0.0048)	-0.0049 (0.0040)		-0.0048 (0.0119)	-0.0011 (0.0074)		-0.0144 (0.0147)	-0.0251* (0.0151)	
GDPGrow	0.0681 (0.0503)		-0.0128 (0.0275)	0.0494 (0.0704)		0.0694*** (0.0191)	0.0346 (0.0920)	0.0124 (0.0904)	
Inflation	-1.5309*** (0.0503)		-0.7162*** (0.0829)	-1.5027*** (0.3449)		-0.5089** (0.0984)	0.2076 (0.2998)	0.9528*** (0.2028)	
LoanGrow	0.0039 (0.0064)		-0.0021 (0.0022)	0.0074* (0.0042)		-0.0024 (0.0034)	-0.0275* (0.0146)	-0.0083** (0.0038)	
TotAtGrow	-0.0656*** (0.0167)		-0.0251*** (0.0022)	-0.0076 (0.0135)		-0.0033 (0.0053)	0.0026 (0.0107)	-0.0137** (0.0054)	
LnAsset	-0.3662** (0.1745)		-0.1478*** (0.0366)	-0.3574** (0.1367)		-0.1630** (0.0356)	-0.2221* (0.1308)	-0.0857** (0.0398)	
Crise	0.3720 (0.6571)		0.7642*** (0.1482)	0.1951 (0.6276)		0.6637*** (0.1508)	0.4869 (0.5720)	1.5338*** (0.2890)	

Continuação da Tabela 7

R-squared	0.235658	0.152980	0.069014	0.183500	0.112731	0.037526	0.162121	0.132386	0.061073
Prob(LR statistic)	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000
Log likelihood	-197.3423	-288.258	-852.1546	-233.9092	-327.428	-839.5401	-232.0535	-310.9058	-749.417

O número na posição superior representa o coeficiente da variável explicativa, e o número entre parênteses representa o Std. Error.

*, ** e *** representam a significância estatística a 1%, 5% e 10%, respetivamente.

A primeira parte da Tabela 7 mostra os diferentes modelos com desfaseamento temporal de um ano, ou seja, com os valores das variáveis um ano antes do *distress*. No modelo com todas as variáveis (I.1) verificamos que apenas 6 das 23 variáveis são estatisticamente significativas. Destas 6 variáveis apenas três vão de encontro com a literatura, nomeadamente as variáveis Eq_NetLoan, OthOpInc_AvgAt e TotAtGrow. O coeficiente do logaritmo natural do Total do Ativo (LnAsset) assume valores negativos e estatisticamente significativos a, pelo menos, 10%, em todos os modelos em que está presente, tal como o previsto por Ploeg (2010). Já o coeficiente da variável inflação apresenta-se em todos os modelos com os dados de um e dois anos antes do evento de *distress*, mas já no modelo III.1 com desfaseamento temporal de três anos, o coeficiente já se apresenta positivo como o defendido na literatura, o que nos leva a crer que o efeito da taxa de inflação poderá se sentir mais no longo prazo. Podemos realçar também que a variável Crise apresenta-se estatisticamente significativa a 1% nos modelos com apenas as outras variáveis, em todos os desfaseamentos temporais, o que nos dá a entender que um banco sediado num país em Crise tenha maior probabilidade de *distress*, apoiando a Hipótese H1.

Na segunda parte da tabela são apresentados os modelos com desfaseamento temporal de dois anos. No modelo I.2 as variáveis Reserva para perdas em empréstimos concedidos sobre Empréstimos brutos (LoanLRes_GrLoan), ROAA e Despesas em juros sobre Passivo total (IntExp_Liab) apresentam-se estatisticamente significativas e com sinais que apoiam a literatura relacionada. A variável ROAE, de acordo com alguns estudos, como o de Messai e Jouini (2013), pode apresentar sinal positivo ou negativo. Neste caso verifica-se um sinal positivo, mas apenas neste modelo. O coeficiente da variável Despesas em juros sobre Passivo total apresenta-se, em todos os modelos, seja de forma significativa ou não, negativo, ao contrário do que o esperado. No modelo III.2, quatro das seis variáveis apresentam-se estatisticamente significativas a 1%, embora o crescimento real do PIB tenha o efeito

contrário ao previsto na literatura, mas podendo ser explicado por ser um período pós-crise, onde as economias mais afetadas estejam a recuperar.

Por fim, na parte da Tabela 7 que diz respeito ao desfasamento temporal de três anos, é de realçar o modelo III.3, onde 5 das 6 variáveis têm coeficientes estatisticamente significativos.

Na Tabela 8 apresentam-se os resultados dos mesmos modelos para a variável rácio de capital (Y_{dis}). Na primeira parte desta tabela, é possível verificar-se um grande aumento de variáveis explicativas estatisticamente significativas, em comparação com os modelos efetuados tendo em consideração a variável falência (Y_{fal}). Das variáveis do modelo I.1 que são significativas apenas duas não vão de encontro com o esperado, nomeadamente as variáveis Empréstimos Concedidos sobre Passivo Total e Rendimento de *trading* sobre Rendimento Operacional. A grande maioria das variáveis explicativas dos três modelos da primeira parte da tabela são estatisticamente significativas a, pelo menos, 5%. Numa análise mais específica, a variável taxa de Inflação, ao contrário do verificado na Tabela 7, apresenta um coeficiente positivo, de acordo com o esperado, esperado em todos os modelos em que a variável é utilizada. No que concerne à variável Crise, tal como aconteceu nos modelos da Tabela 7, apresenta-se sempre significativa nos modelos com apenas as outras variáveis.

Os modelos elaborados com desfasamento temporal de 2 anos, em relação aos modelos com lag1, têm um decréscimo acentuado de variáveis explicativas significativas, e até do seu nível de significância. Nestes modelos, o rácio Tier 1 e o rácio Depósito de Fundos de curto-prazo sobre o Passivo ($DepShTFund_Liab$) continuam estatisticamente significativas e com sinais concordantes com a literatura. No modelo III.2, verificamos a significância do coeficiente da taxa de crescimento real do PIB, com sinal negativo, de acordo com os estudos anteriores. Contudo, a taxa de crescimento de Empréstimo, apesar de estatisticamente significativa, apresenta um sinal contrário ao esperado.

Apesar dos modelos II e III nos darem uma visão mais ampla da significância dos vários conjuntos de variáveis, verifica-se que, tanto nos modelos com variável dependente falência como rácio de capital, que os modelos com todas as variáveis apresentam maior R-squared, o que apoia a Hipótese H3, na medida em que os modelos com todas as variáveis apresentam maior significância. Noutra perspetiva, e em termos de comparação, os modelos desenvolvidos com a variável dependente Y_{dis} apresentam maior significância de variáveis e maior R-squared do que os modelos desenvolvidos primeiramente. Assim apercebemo-nos

que, apesar de ambas as variáveis dependentes serem *proxies* de *bank distress*, têm resultados diferentes, tanto a nível de significância como de alguns sinais, o que suporta a Hipótese H4. E, de um modo geral podemos afirmar que existem algumas variáveis CAMELS que são estatisticamente significantes, o que nos pode levar a apoiar em parte a Hipótese 2.

Por último, a partir do modelo I.1 da Tabela 8, pois é o mais significativo e relevante do estudo, e através do método *stepwise-backward*, serão retiradas as variáveis com menor significância de modo a obtermos um modelo onde as variáveis explicativas são significativas a, pelo menos, 5%. Os resultados deste modelo estão representados na Tabela 9.

Neste modelo final deixamos de ter 23 variáveis explicativas para apenas termos 11. Observamos também que o R-squared do modelo final (0.464254) acabou por não diminuir muito em relação ao modelo inicial com todas as variáveis (0.492495).

Segundo este último modelo, podemos afirmar que a probabilidade de *distress* de um banco está associada positivamente aos rácios ROAE, Depósitos e fundos de curto-prazo sobre o total do Ativo, Empréstimos concedidos sobre o total do Passivo e pela taxa de Inflação, e está associada negativamente pelos rácios: Capital Próprio sobre o total do Ativo, Tier 1, ROAA, Depósitos e fundos de curto-prazo sobre o total do Passivo, Empréstimos concedidos sobre Depósitos e fundos de curto-prazo, Rendimento de *trading* sobre Rendimento operacional e a taxa de crescimento dos Empréstimos concedidos.

Tabela 8- Resultados do Modelo Logit - variável dependente rácio de capital (Ydis)

Variável	Lag1			Lag2			Lag3		
	I.1	II.1	III.1	I.2	II.2	III.2	I.3	II.3	III.3
C	9.7095* (5.4557)	5.1067 3.1381	-8.3264*** 0.9084	-2.8613 (5.7446)	1.5298 2.0095	-7.1096*** 1.2568	-2.4800 (13.7337)	4.6981 3.7196	-7.0795*** 1.5930
Eq_TotAt	-0.5541*** (0.1966)	-0.4547*** 0.1311		0.0806 (0.0871)	-0.1344 0.1552		-0.3747 (0.6499)	-0.3588 0.4379	
Eq_NetLoan	0.0045 (0.0049)	0.0045 0.0041		-0.0227 (0.0417)	-0.0170 0.0210		-0.1188 (0.1240)	-0.0045 0.0261	
Tier1	-0.5124*** (0.1854)	-0.4183*** 0.1201		-0.3610*** (0.1007)	-0.2474** 0.1078		-0.4741*** (0.1597)	-0.2528*** 0.0886	
NetLoan_TotAt	-0.1357* (0.0763)	-0.0147 0.0538		-0.0087 (0.1021)	0.0388 0.0753		-0.9363** (0.4537)	-0.3386 0.4785	
OthOpInc_AvgAt	0.3910 (0.8516)	-0.3072 0.6446		0.3311 (0.6966)	0.6258 0.5437		0.7233 (1.0453)	0.1711 0.4855	
LoanLRes_GrLoan	0.0579 (0.0352)	0.0491 0.0442		0.0029 (0.0534)	0.0410 0.0361		-0.1030 (0.0649)	0.0080 0.0386	
CostToInc	0.0025 (0.0042)	0.0041 0.0037		-0.0158 (0.0141)	-0.0115 0.0103		-0.0002 (0.0039)	0.0053 0.0073	
Oplnc_Asset	-26.856 (54.6269)	33.4019 41.7602		-27.5770 (58.6840)	-45.8195 40.4315		-20.4563 (102.618)	-19.0213 44.7593	
ROAE	0.0731*** (0.0209)	0.0329 0.0316		0.0092 (0.0216)	0.0252 0.0185		0.0430 (0.0282)	0.0520** 0.0210	
ROAA	-0.8613** (0.3922)	-0.4593 0.6071		-0.5568 (0.6479)	-0.6461* 0.3551		-1.0645*** (0.3699)	-0.9055*** 0.2920	
NetIntMargin	-0.0922 (0.4994)	-0.1558 0.4285		-0.2144 (0.7084)	-0.2173 0.5127		-0.1612 (1.0290)	-0.2238 0.6721	
IntExp_Liab	-1.2529 (33.1798)	47.9486* 26.7136		41.8475 (38.2165)	51.8391* 27.4875		50.7694 (52.5000)	29.2574 45.2359	
DepShtFund_At	3.1616** (1.5847)	-1.3371 1.8778		4.3960 (2.3996)	0.9770 0.8822		7.7204 (5.9866)	0.7483 1.1879	
DepShtFund_Liab	-11.6484** (4.5300)	-3.1441 3.4128		-2.3849* (3.5648)	-1.8212 2.1105		-6.3173 (9.1926)	-6.8004** 3.1882	
Loan_Liab	22.5483*** (8.4126)	6.4594 5.6331		0.2983 (9.4454)	-2.3541 6.9599		87.8395* (46.5058)	36.5614 47.1284	
Loan_DepShTFund	-6.2617** (3.0288)	-2.5590 1.9823		-0.0771 (0.6170)	-0.6543 0.7428		-0.8249 (5.9898)	-2.4263 2.3802	
TradRev_OpRev	-0.0258*** (0.0065)	-0.0153*** 0.0050		-0.0044 (0.0074)	-0.0026 0.0062		0.0124 (0.0294)	0.0184 0.0271	
GDPGrow	0.1997 (0.1760)		-0.1083 0.0754	0.0826 (0.1123)		-0.1816*** 0.0498	0.1013 (0.3875)	-0.2742*** 0.0551	
Inflation	1.5255*** (0.4806)		0.5921*** 0.1736	0.8972** (0.4283)		0.1945 0.1533	2.2808* (1.2819)	0.4803*** 0.1974	
LoanGrow	-0.0265 (0.0196)		-0.0014 0.0017	-0.0252 (0.0203)		0.0029** 0.0014	-0.0482* (0.0290)	-0.0010** 0.0050	
TotAtGrow	-0.0029 (0.0214)		0.0012 0.0071	-0.0115 (0.0238)		-0.0076 0.0061	-0.0433 (0.0349)	-0.0015 0.0069	
LnAsset	0.0100 (0.1788)		0.1820*** 0.0617	0.1204 (0.2782)		0.0999 0.0870	0.1013 (0.4356)	-0.0045 0.1077	
Crise	0.5948 (0.6455)		1.7884*** 0.2878	1.0064 (0.8442)		1.7275* 0.2954	3.6891* (1.8874)	2.6093*** 0.4559	

Continuação da Tabela 8

R-squared	0.492495	0.443918	0.076217	0.322455	0.297630	0.084595	0.423392	0.227357	0.160981
Prob(LR statistic)	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000015	0.000017	0.000000
Log likelihood	-111.006	-190.842	-482.291	-92.7082	-145.091	-299.475	-42.6961	-89.3440	-174.029

O número na posição superior representa o coeficiente da variável explicativa, e o número entre parênteses representa o Std. Error.

*, ** e *** representam a significância estatística a 1%, 5% e 10%, respetivamente.

Tabela 9- Resultados do Modelo Final - variável dependente rácio de capital - método stepwise-backward

Variável	Lag1
	Modelo Reduzido
C	16.5736*** (3.6350)
Eq_TotAt	-0.2971** (0.1171)
Tier1	-0.5602*** (0.1573)
ROAE	0.0753*** (0.0202)
ROAA	-0.9976** (0.4018)
DepShtFund_At	2.4487** (0.9630)
DepShtFund_Liab	-18.7865*** (4.4849)
Loan_Liab	15.9330*** (4.5389)
Loan_DepShTFund	-11.6026*** (3.1462)
TradRev_OpRev	-0.0299*** (0.0069)
Inflation	0.9421*** (0.3070)
LoanGrow	-0.0372** (0.0180)
R-squared	0.464254
Prob(LR statistic)	0.000000
Log likelihood	-120.5038

O número na posição superior representa o coeficiente da variável explicativa, e o número entre parênteses representa o Std. Error.

*, ** e *** representam a significância estatística a 1%, 5% e 10%, respetivamente.

5. Conclusão

A crise financeira na Europa deixou uma grande preocupação pelo setor bancário em geral, deixando em alerta as autoridades bancárias para qualquer sinal de alarme. O que fez que trabalhos, como este, tenham vindo a ser desenvolvidos, de forma a fornecer uma ferramenta de previsão de *distress* bancário na Zona Euro.

Para esta investigação foram utilizados dados de 2012 a 2017 de 4046 bancos da Zona Euro, utilizando a base de dados Orbis Bank Focus. Foram selecionadas, de entre a vasta literatura relacionada, variáveis CAMELS e não-CAMELS que se consideraram mais importantes. Uma das grandes diferenças deste trabalho é o facto de se usar duas variáveis dependentes distintas (falência e rácio de capital) e comparar os resultados obtidos nos modelos com as diferentes variáveis dependentes. A nível metodológico, optou-se por utilizar a regressão *logit* para o modelo de previsão de *distress* bancário, pois foi um dos mais utilizados ao longo dos tempos e que apresentou melhores resultados. Este modelo também adapta-se bem ao problema, na medida em que conseguimos dicotomizar as duas variáveis dependentes em 1 e 0 (1 para bancos em *distress* e 0 para banco saudáveis). Em todos os modelos desenvolvidos foi adotado o método de correção de Huber-White para evitar problemas de heterocedasticidade.

Foram desenvolvidos modelos completos com todas as variáveis e outros parciais com apenas um dos tipos de variáveis explicativas, e com diversos desfasamentos temporais, desde um, dois e três anos antes do momento de *distress*, e isto para cada variável dependente.

Nos resultados na análise univariada, já foi possível perceber-se que existe uma diferença nos valores médios das variáveis explicativas para cada tipo de banco (em *distress* ou saudável), tendo em conta as diferentes variáveis dependentes. Verificou-se que a diferença entre os valores médios dos bancos em *distress* e dos bancos saudáveis é superior quando se tem em consideração a variável dependente rácio de capital.

Validou-se a Hipóteses H4, que nos diz que os resultados dos modelos obtidos com diferentes variáveis dependentes *proxies* de *bank distress* podem não ser iguais, na medida em que os modelos *logit* produzidos com a variável dependente falência apresentam um menor número de variáveis estatisticamente significantes, em relação aos modelos com a variável

rácio de capital, e ainda verifica-se que alguns dos sinais dos coeficientes obtidos não são iguais.

A Hipótese H1 foi também aceite, pois o coeficiente da variável Crise apresenta sinal positivo e estatisticamente significativo em todos os modelos, com apenas as variáveis CAMELS e para qualquer desfasamento temporal. Apesar dos modelos com apenas um dos tipos de variáveis nos darem uma visão mais direta da significância das variáveis de cada tipo, os modelos completos são os que apresentam maior significância global, o que vem apoiar as Hipótese H3. Já a Hipótese H2 pode ser aceite em parte, na medida em que algumas variáveis CAMELS apresentam influência sobre a probabilidade de distress, mas outras não.

Por fim, foi elaborado um último modelo através do método de *stepwise-backward*, que partiu do modelo completo com desfasamento temporal de um ano, com variável dependente rácio de capital. Este modelo apresenta todas as variáveis estatisticamente significantes a 5%. Com este modelo final, podemos concluir que a probabilidade de distress aumenta com o aumento das variáveis: ROAE, Depósitos e fundos de curto-prazo sobre o total do Ativo, Empréstimos concedidos sobre o total do Passivo e taxa de Inflação, e diminui com o aumento das variáveis: Capital Próprio sobre o total do Ativo, Tier 1, ROAA, Depósitos e fundos de curto-prazo sobre o total do Passivo, Empréstimos concedidos sobre Depósitos e fundos de curto-prazo, Rendimento de *trading* sobre Rendimento operacional e a taxa de crescimento dos Empréstimos concedidos.

Uma das limitações que se pode apontar a esta investigação é o facto de não se poder ter feito uma análise pré-crise e pós-crise, na medida em que na base de dados utilizada apenas são disponibilizados dados a partir do ano 2012.

Concluindo, foi possível através deste trabalho construir modelos eficazes, e um modelo final estatisticamente significativo que poderá servir de instrumento de previsão de *distress*. De forma a complementar este trabalho, os modelos podem ser individualizados para cada país com outras variáveis mais específicas.

6. Referências Bibliográficas

- Altman, E. I. (1968). Financial Ratios, Discriminant Analysis and The Prediction of Corporate Bankruptcy. *The Journal of Finance*, 23(4), 589-609.
- Altman, E. I. (2000). Predicting financial distress of companies: Revisiting the Zscore and Zeta Models. *Journal of Banking and Finance*, 1, 428-456.
- Altman, E. I., Cizel, J., Rijken, H. A. (2014). Anatomy of Bank Distress: The Information Content of Accounting Fundamentals Within and Across Countries. *SSRN Working Paper*, 1-34.
- Andersen, H. (2008). Failure prediction of Norwegian banks: a logit approach. *Norges Bank Working Paper*.
- Beaver, W. (1966). Financial Ratios As Predictors of Failure. *Journal of Accounting Research*, 4, 71-111.
- Betz, F., Opricã, S., Peltonen, T. & Sarlin, P. (2014). Predicting distress in European banks. *Journal of Banking and Finance*, 45, 225-241.
- Carapeto, M., Moeller, S., Faelten, A., Vitkova, V., & Bortolotto, L. (2010). Distress classification measures in the banking sector. *Technical Report*, Cass Business School, City University of London.
- Carvalho das Neves, J. (2007). Análise de Risco e Custo de Capital Alheio. *Análise Financeira: Técnicas Fundamentais* (Parte III, Cap. 10, 202-237). 1ª ed. Lisboa: Texto Editores.
- Cole, R. & Wu, Q. (2009). Is Hazard or Probit more Accurate in Predicting Financial Distress? Evidence from U.S. Bank Failures. *Working Paper*.
- Demirguc-Kunt, A. (1989). Deposit-institution failures: a review of empirical literature. *Economic Review*, 25, 2-11.
- Flannery, M. (1998). Using Market Information in Prudential Bank Supervision: A Review of the U.S. Empirical Evidence. *Journal of Money, Credit and Banking*, 30(3), 273-305.
- Hillegeist, S. A., Keating, E., Cram, D. & Lundstedt, K. (2004). Assessing the probability of bankruptcy. *Review of Accounting Studies*, 9, 5-34.

- Jordan, D. J., Rica, D., Sanchez, J., Walker, C. & Wort, D. H. (2010). Predicting Bank Failures: Evidence from 2007 to 2010. *SSRN Working Paper*.
- Kane, E. (1985). *The Gathering Crisis in Federal Deposit Insurance*. Cambridge, MA: MIT Press.
- Khaddafi, M., Falahuddin, Heikal, M., Nandari, A. (2017). Analysis Z-score to Predict Bankruptcy in Banks Listed in Indonesia Stock Exchange. *International Journal of Economics and Financial Issues*, 7(3), 326-330.
- Kolari J., Glennon, D., Shin, H., Caputo, M. (2002). Predicting large US commercial bank failures. *Journal of Economics and Business*, 54, 361-387.
- Konstandina, N. (2006). Probability of Bank Failure: The Russian Case. *Economic Education and Research Consortium, Working Paper*, No. 06/01.
- Kouki, M. & Elkhaldi, A. (2011). Toward a Predicting Model of Firm Bankruptcy: Evidence from the Tunisian Context. *Middle Eastern Finance and Economics*, 14, 26-43.
- Kuznetsov, A. (2003). Crisis of 1998 and determinants of stable development of a bank. *Working paper, BSP/2003/062 E. – Moscow: New Economic School*.
- Lennox, C. (1999). Identifying failing companies: a reevaluation of the logit, probit and DA approaches. *Journal of Economics and Business*, 51(4).
- Lin, S. L. (2010). A two-stage logistic regression-ANN model for the prediction of distress banks: Evidence from 11 emerging countries. *African Journal of Business Management*, 14(4), 3149-3168.
- Logan, A. (2001). The United Kingdom's small banks' crisis of the early 1990s: What were the leading indicators of failure?. *Bank of England Working Paper*, No. 139.
- Maghyereh, A. & Awartani, B. (2014). Bank distress prediction: empirical evidence from the Gulf Cooperation Council countries. *Research in International Business and Finance*, 30, 126–147.
- Männasso, K. & Mayes, D. G. (2005). Investigating the Early Signals of Banking Sector Vulnerabilities in Central and East European Emerging Markets. *Working Paper of Eesti Pank*, No. 8/2005.

- Männasso, K. & Mayes, D. G. (2009). Explaining Bank Distress in Eastern European Transition Economies. *Journal of Banking & Finance*, 33(2), 244-253.
- Martin, D. (1977). Early Warning of Bank Failure. A Logistic Regression Approach. *Journal of Banking and Finance*, 1, 249-276.
- Mayes, D. & H. Stremmel (2014). The Effectiveness of Capital Adequacy Measures in Predicting Bank Distress. Chapters in SUERF Studies, *SUERF – The European Money and Finance Forum*.
- Messai, A. & Jouini, F. (2013). Predicting Banking Distress in European Countries. *Journal of Economic and Social Studies*, 3, 61-83.
- Ohlson, J. (1980). Financial Ratios and the Probabilistic Prediction of Bankruptcy. *Journal of Accounting Research*, 18, 109-131.
- Oluwakayode, A. (2017). Causes and Effects of Banking Distress in Nigeria Banking Industry, *International Academic Journal of Accounting and Financial Management*, 4(1), 100-105.
- Ploeg, S. (2010). Bank Default Prediction Models: A Comparison and an Application to Credit Rating Transitions. MA thesis, Erasmus School of Economics Rotterdam
- Poghosyan, T. & Cihák, M. (2009). Distress in European Banks: An Analysis Based on a New Dataset. *IMF Working Papers*.
- Poghosyan, T. & Cihák, M. (2011). Determinants of bank distress in Europe: Evidence From a New Data Set. *Journal of Financial Services Research*, 40(3), 163–184.
- Rojas-Suarez, L. (2002). Rating Banks in Emerging Markets: What credit Agencies Should Learn from Financial Indicators. *Institute for International Economics Working Paper*, 01-6.
- Shumway, T. (2001). Forecasting bankruptcy more accurately: a simple hazard model. *Journal of Business*, 74, 101-124.
- Thomson, J. B. (1991). Predicting bank failures in the 1980s. *Economic Review*, 27 (1), 9-20.
- Vilén, M. (2010). *Predicting Failures of Large U.S. Commercial Banks*. Master's Thesis, Aalto University School of Economics.
- Wang, X. & Ji, Z. (s.d.). Bank Failure Prediction: Empirical Evidence from US & UK Banks – Impact of Derivatives and Other Balance Sheet Items. disponível em:

https://mediacast.blob.core.windows.net/production/Faculty/StoweConf/submissions/s_wfa2014_submission_228.pdf, aceso a 10 de maio de 2018.

Watson, J. & J. E. Everett (1993). Defining small business failure. *International Small Business Journal*, 11, 35–48.

Wu, Y., Gaunt, C. & Gray, S. (2010). A comparison of alternative bankruptcy prediction models. *Journal of Contemporary Accounting and Economics*, 6, 34-45.

Zavgren, C. V., (1985). Assessing the Vulnerability to Failure of American Industrial Firms: a Logistic Analysis. *Journal of Business Finance and Accounting*, 12(1), 19-45.

Zmijewski, M. E. (1984). Methodological issues related to the estimation of financial distress prediction models. *Journal of Accounting Research*, 22, 59-82.