

UNIVERSIDADE PRESBITERIANA MACKENZIE
CENTRO DE CIÊNCIAS SOCIAIS APLICADAS
PROGRAMA DE PÓS-GRADUAÇÃO EM ADMINISTRAÇÃO DE EMPRESAS

Flávio Luiz de Moraes Barboza

Modelos Computacionais e Probabilísticos em Riscos de Crédito

São Paulo
2015

Flávio Luiz de Moraes Barboza

Modelos Computacionais e Probabilísticos em Riscos de Crédito

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Administração de Empresas da Universidade Presbiteriana Mackenzie, como requisito parcial para a obtenção do título de Doutor em Administração de Empresas, Linha de Finanças Estratégicas.

Orientador: Prof. Dr. Leonardo Fernando Cruz Basso
Universidade Presbiteriana Mackenzie

São Paulo
2015

B238c Barboza, Flávio Luiz de Moraes
Modelos Computacionais e Probabilísticos em Riscos de Crédito / Flávio Luiz de Moraes Barboza - 2015.
113 f. : 30cm

Tese (Doutorado em Administração de Empresas) -
Universidade Presbiteriana Mackenzie, São Paulo, 2015.
Orientação: Prof. Dr. Leonardo Fernando Cruz Basso
Bibliografia: f. 100 - 113

1.Risco de Crédito 2.Capital Econômico 3.*Ratings* 4.Falências 5.Aprendizagem de Máquinas I.Título.

CDU 658.151

Reitor da Universidade Presbiteriana Mackenzie
Prof. Dr. Benedito Guimarães Aguiar Neto

Decano de Pesquisa e Pós-Graduação
Professora Dra. Helena Bonito Couto Pereira

Coordenadora Geral de Pós-Graduação Stricto Sensu
Professora Dra. Angélica Tanus Benatti Alvim

Coordenador do Programa de Pós-Graduação em Administração
de Empresas
Professor Dr. Walter Bataglia

Flávio Luiz de Moraes Barboza

Modelos Computacionais e Probabilísticos em Riscos de Crédito

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Administração de Empresas da Universidade Presbiteriana Mackenzie, como requisito parcial para a obtenção do título de Doutor em Administração de Empresas, Linha de Finanças Estratégicas

Aprovada em

BANCA EXAMINADORA

Prof. Dr. Leonardo Fernando Cruz Basso
Universidade Presbiteriana Mackenzie

Prof. Titular Herbert Kimura
Universidade de Brasília

Prof. Dr. Vinicius Amorim Sobreiro
Universidade de Brasília

Prof. Dr. Denis Forte
Universidade Presbiteriana Mackenzie

Profa. Dra. Michele Nascimento Juca
Universidade Presbiteriana Mackenzie

Resumo

Esta tese estuda risco de crédito com o intuito de promover uma discussão sobre a amplitude da literatura científica e dois destacados temas: capital regulatório e modelagem de previsão de falências. Para tanto dividiu-se o material em três ensaios. O primeiro é, na sua essência, uma revisão de literatura. Os principais estudos sobre risco de crédito foram classificados e codificados, e uma abordagem baseada em citação foi utilizada para determinar a sua relevância e contribuições. Lacunas interessantes do conhecimento são encontradas neste trabalho, o que nos dá motivação para desenvolver dois assuntos. O segundo discute a influência da busca por posições de *rating* mais elevadas para as estratégias das instituições financeiras quando visam minimizar o capital econômico, considerando *rating* de crédito do tomador e de seu *rating* objetivo em si. Usando um modelo de distribuição probabilística para simular a perda dada a inadimplência (mais conhecida por *loss given default*, *LGD*), os resultados encontrados mostram que o uso de notações de crédito nas orientações para o cálculo dos requisitos mínimos de capital pode ser uma alternativa para os bancos. No entanto, achou-se possível obter uma melhor classificação dentro de alguns pequenos intervalos de *LGD*. O terceiro mostra uma análise comparativa do desempenho de modelos computacionais, que são amplamente utilizados para resolver problemas de classificação e métodos tradicionais aplicados para prever falhas um ano antes do evento. Os modelos são formulados por meio de técnicas de aprendizagem de máquinas (máquinas de vetores de suporte, *bagging*, *boosting* e *random forest*). Aplicando dados de empresas norte-americanas 1985-2013, comparamos os resultados destes métodos inovadores com redes neurais, regressão logística e análise discriminante. O principal resultado desta parte do estudo é uma melhoria substancial no poder de previsão usando técnicas de aprendizado de máquina, quando, além das variáveis do *Z-Score* original de [Altman \(1968\)](#), seis métricas (ou constructos) selecionadas a partir de [Carton e Hofer \(2006\)](#) são incluídas como variáveis explicativas. A análise mostra que os modelos *bagging* e *random forest* tem desempenho superior as outras técnicas; todas as previsões são melhoradas quando os constructos sugeridos são incluídos na pesquisa.

Palavras-Chave: Risco de Crédito, Capital Econômico, *Rating*, Falência, Aprendizagem de Máquinas.

Abstract

This dissertation studies credit risk to promote a discussion about the breadth of scientific literature and two highlighted topics: regulatory capital and bankruptcy prediction modeling. These issues are divided among three essays. The first one is a review of literature in nature. The main studies on credit risk were classified and coded, and a citation-based approach was used to determine its relevance and contributions. Interesting omissions of knowledge are found in this work, which give us motivation to develop two subjects. The second essay discusses the influence of the desire for higher rating positions for financial institutions' strategies when aiming to minimize economic capital, considering the borrower's credit rating and target rating itself. Using a probabilistic distribution model to simulate loss-given default (LGD), our results show that the use of credit ratings in the guidance for calculating minimum capital requirements can be an alternative to the banks. Yet, we find it possible to get better rankings to lend to some small intervals of LGD. The third study shows a comparative analysis in the performance of computational models, which are widely used to solve classification problems, and traditional methods applied to predict failures one year before the event. The models are formulated by machine learning techniques (support vector machines, bagging, boosting and random forest). Applying data from U.S. companies from 1985 to 2013, we compare the results of these innovative methods with neural networks, logistic regression, and discriminant analysis. The major result of this part of the study is a substantial improvement in predictive power by using machine learning techniques, when, besides the original variable Z-Score from Altman (1968), six metrics (or constructs) selected from Carton e Hofer (2006) are included as explanatory variables. The analysis shows that the bagging and the random forest models outperform other techniques; all predictions are improved when the suggested constructs are included in the survey.

Keywords: *Credit Risk, Economic Capital, Rating, Bankruptcy, Machine Learning.*

Agradecimentos

Eu gostaria de agradecer primeiramente a Ana Cláudia pela paciência, apoio incontestável, companhia e discussões, aos meus pais José Luiz e Elina, aos meus irmãos Junior e Leonardo, aos vários amigos que me encontraram nesta empreitada: Fabio, Bianca, Sabrina, Alexandre, Evandro, Ricardo, Rodrigo Chela, João Chela, André Ortiz, André Silva, José Renato, Ronaldo Junio, Magno entre outros (presentes na graduação ou pós-graduação), Thiago H. Silva e Leticia (escola); aos amigos do futebol; aos vizinhos Lorenzo e Adryelle pela companhia; à família Bolognese: Selma, Nilson, filhos e parentes pela hospitalidade nos EUA; Marcos, Eli, Aletheia, Marcio, Helene, Juliana e a todos colegas do curso de pós-graduação do Mackenzie.

Um agradecimento especial ofereço ao meu nobre amigo-irmão, Edison Abreu Rodrigues e seus familiares (Dona Raquel - mãe, Maria do Carmo - irmã) pelo carinho, apreço e respeito por tudo que jamais outras pessoas poderão fazer por mim.

Agradeço imensamente aos professores Herbert Kimura, o qual me ensinou tudo que sei sobre finanças, Leonardo Basso pelo apoio incondicional e sugestões excepcionais sobre fundamentos econômicos, Vinicius Sobreiro pelo apoio e dicas para o aperfeiçoamento na escrita científica, Denis Forte por todos os comentários, discussões nas aulas e em seminários, e, não poderia deixar de fora, ao Prof. Edward Altman pela orientação durante o período em Nova York, nos Estados Unidos, e dentre muitos outros que, de alguma forma, contribuíram para que este trabalho fosse possível.

O suporte financeiro do Banco Santander, CAPES, Centro Paula Souza, e do próprio Mackenzie também precisa ser lembrado neste momento: o meu sincero obrigado por acreditar em um mero estudante.

Ainda, agradeço ao *Credit & Debt Markets Research Program* do *Salomon Center*, da *New York University* e também a Brenda Kuehne (especialista do departamento) por fornecer os dados de empresas falidas.

Sumário

Lista de Figuras	6
Lista de Tabelas	8
1 Introdução	11
2 Revisão da Literatura	15
2.1 Uma Breve Descrição Conceitual sobre Risco de Crédito	17
2.2 Método de Pesquisa	19
2.3 Critérios de Classificação e Codificação	21
2.4 Resultados e Discussão	26
2.5 Conclusões	54
3 Capital Econômico e <i>Ratings</i>: Análise e Requisitos Mínimos	56
3.1 Revisão da Literatura sobre Capital Econômico e seus Determinantes	58
3.1.1 Regulação	61
3.1.2 Capital Econômico e o Modelo de Mensuração	63
3.1.3 <i>Ratings</i> de Empresas de acordo com a Exposição ao Risco de Crédito	66
3.2 Simulação Computacional	66
3.3 Análise e Resultados	71
3.4 Conclusões	76
4 Modelos de Previsão de Falências e Aprendizagem de Máquinas	79
4.1 Fundamentação Teórica	81
4.1.1 <i>Support Vector Machines</i>	81
4.1.2 <i>Bagging</i>	83
4.1.3 <i>Boosting</i>	83
4.1.4 <i>Random Forest</i>	84
4.1.5 Redes Neurais Artificiais	85

4.1.6	Análise Discriminante e Regressão Logística	86
4.2	Dados e Método	86
4.3	Resultados	92
4.4	Conclusões	96
5	Comentários Finais	98
	Referências Bibliográficas	100

Lista de Figuras

2.1	Quantidade de estudos publicados sobre gestão de riscos que forma indexados as principais base de dados acadêmicas. Fonte de dados: <i>Web of Science</i> .	16
2.2	Número de artigos encontrados na busca feita na base de dados da <i>Scopus</i> usando a palavra-chave “ <i>Credit Risk</i> ”.	20
2.3	Total de citações (em milhares) dos principais <i>journals</i> que possuem publicações aplicadas nesta pesquisa. Fonte de dados: <i>Scopus</i> .	29
2.4	Resultado da classificação para a categoria 1 “Tema Principal”.	44
2.5	Resultado da classificação para a categoria 2 “Método Aplicado”.	45
2.6	Resultado da classificação para a categoria 3 “Origem dos Dados”.	46
2.7	Resultado da classificação para a categoria 4 “Local de Origem dos Dados”.	47
2.8	Resultado da classificação para a categoria 5 “Variável de Interesse”.	48
2.9	Resultado da classificação para a categoria 6 “Quantidade de Hipóteses ou Objetivos”.	49
2.10	Resultado da classificação para a categoria 7 “Implicações”.	50
2.11	Resultado da classificação para a categoria 8 “Área de Estudo (<i>JEL</i>)”.	50
2.12	Resultado da classificação para a categoria 9 “Período de Análise”.	51
2.13	Mapa de referências dos 83 artigos analisados nesta seção do trabalho que apresentam pelo menos duas citações de outros artigos que fazem parte deste estudo, denominado citações locais. O tamanho dos círculos (diâmetro) está relacionado à quantidade de citações locais, conforme a Tabela 2.8.	53
3.1	<i>Graphical abstract</i> .	59
3.2	Forma de distribuição das perdas em termos de frequência. Em estudos financeiros, essa curva é útil para descrever o comportamento de perdas em eventos de inadimplência. As expectativas de perdas mais elevadas aumentam à medida que a frequência diminuiu, mas apenas para perdas esperadas muito elevadas. O capital econômico pode ser visualizado como a proporção da <i>UL</i> para além do nível de <i>EL</i> .	65

3.3	Gráfico da função densidade de probabilidade (<i>PDF</i>) da distribuição Beta para os parâmetros $\alpha = 2$ e $\beta = 5$, como um exemplo. Esta <i>PDF</i> pode substituir a distribuição de perdas quando os parâmetros α e β são calibrados de forma adequada. Este tratamento é necessário porque a média e o desvio padrão que determinam a distribuição teórica, <i>EL</i> e <i>UL</i> , respectivamente, podem ser calculados.	67
3.4	Descrição passo-a-passo do método aplicado neste capítulo.	72
3.5	Capital econômico para credor com objetivo de alcançar diferentes níveis de <i>rating</i> , baseado na simulação da <i>LGD</i> do tomador de <i>rating A</i>	73
3.6	Capital econômico para credor com objetivo de alcançar diferentes níveis de <i>rating</i> , baseado na simulação da <i>LGD</i> do tomador de <i>rating BBB</i>	74
3.7	Capital econômico para credor com objetivo de alcançar diferentes níveis de <i>rating</i> , baseado na simulação da <i>LGD</i> do tomador de <i>rating BB</i>	75
3.8	Capital econômico para credor com objetivo de alcançar diferentes níveis de <i>rating</i> , baseado na simulação da <i>LGD</i> do tomador de <i>rating B</i>	75
4.1	Empresas solventes presentes na amostra de treinamento, apresentadas por ano e indústria. Fonte: preparado pelo autor com dados extraídos do <i>Salomon Center – NYU</i> e da base de dados <i>Compustat</i>	87
4.2	Empresas falidas por ano e indústria, de um total de 449 na amostra de treinamento. Os dados cobrem um período de pouco mais de 20 anos e considera dados de falência para uma ano antes do evento. Fonte: preparado pelo autor com dados extraídos do <i>Salomon Center – NYU</i> e da base de dados <i>Compustat</i>	88
4.3	<i>Graphical Abstract</i> – 11 variáveis foram selecionadas, incluindo as variáveis do <i>Z-Score</i> de Altman e medidas de crescimento, variação, e margem operacional, como sugerido por Carton e Hofer (2006). Modelos de aprendizagem de máquina usados: máquinas de vetores de suporte usando <i>kernels</i> de base lineares e radiais, <i>boosting</i> , <i>bagging</i> e <i>random forest</i> . Os modelos tradicionais utilizados: redes neurais artificiais, regressão logística e análise discriminante multivariada. Os resultados são apresentados como matrizes de confusão e curvas <i>ROC</i>	91
4.4	Curva <i>ROC</i> de todos os modelos para prever a falência a partir de 2006 até 2014, com dados coletados na base de dados <i>Compustat</i> e <i>Salomon Center–NYU</i> . MDA e SVM-Lin mostram menor acurácia, ao mesmo tempo <i>Boosting</i> , <i>Bagging</i> e <i>Random Forest</i> mostram maior poder preditivo.	95

Lista de Tabelas

2.1	Categorias e Códigos aplicados neste estudo com os respectivos significados.	23
2.2	Lista dos principais pesquisadores em ordem decrescente de quantidade de publicações no período de 2000 a 2014. Fonte de dados: <i>Web of Science</i> .	27
2.3	Quantidade de artigos publicados considerando a instituição de origem do principal autor.	27
2.4	País de origem dos pesquisadores e as respectivas instituições em ordem de número de publicações.	28
2.5	<i>Journals</i> ordenados de acordo com a representatividade de artigos na amostra. Fonte de dados: <i>Scopus, Web of Science e Proquest</i> . * NC significa Não Computado.	28
2.6	Classificação dos artigos de acordo com os códigos apresentados na Tabela 2.1 em cada uma das nove categorias analisadas nesta pesquisa.	32
2.7	Descrição sucinta dos principais objetivos, conclusões e contribuições de cada artigo discutido neste estudo.	43
2.8	Artigos presentes nesta pesquisa com duas ou mais citações (i.e., $NLC \geq 2$) de outros artigos dentro da amostra de artigos incluídos nesta revisão da literatura. A última coluna mostra a quantidade de citações do artigo na literatura como um todo (GQC). Fonte de dados: <i>Web of Science</i>	52
3.1	Dados coletados da Probabilidade de <i>default</i> (<i>PD</i>) a partir de relatórios da <i>Moody's</i> baseados nas médias acumuladas nos últimos 20 anos em cada período. Nota: a classificação <i>AA</i> apresenta maior <i>PD</i> do que a classificação <i>A</i> em 1998. <i>LGD</i> dados coletados a partir dos relatórios da Society of Actuaries para os anos de 1998 e 2002 para as mesmas classificações dos relatórios da <i>Moody's</i> . A classificação <i>AAA</i> não foi apresentada para os anos dessa análise. Fonte de dados: Moody's Investors Service (1999), Moody's Investors Service (2003), e Society of Actuaries (2002), Society of Actuaries (2006).	68
3.2	Capital Econômico (em termos percentuais) calculado por meio de dados de credores classificados em 4 níveis: <i>A</i> , <i>BBB</i> , <i>BB</i> e <i>B</i> . Esta análise foi feita também com dados disponíveis em dois anos distintos, 1998 e 2002.	78

4.1	Variáveis preditoras do modelo de previsão de falência um ano antes do evento em si. Se a data de anúncio da falência ocorrer em até seis meses após o fechamento do ano fiscal, os dados coletados são apurados um ano antes. Algumas medidas requerem registros ao longo do tempo e, dessa forma, essas variáveis requerem dados de até três anos anteriores.	89
4.2	Forma da matriz de resultados da classificação, ilustrando a posição com que se apresenta os dados de saída em uma tabela. Os resultados deste trabalho são mostrados nesse padrão.	90
4.3	Matriz de confusão para o modelo de MDA.	92
4.4	Matriz de confusão para o modelo de <i>Logit</i>	92
4.5	Matriz de confusão para o modelo de Redes Neurais.	92
4.6	Matriz de confusão para o modelo de SVM com <i>kernel</i> linear.	92
4.7	Matriz de confusão para o modelo de SVM com <i>kernel</i> de função de base radial (SVM-RBF).	92
4.8	Matriz de confusão para o modelo de <i>Boosting</i>	93
4.9	Matriz de confusão para o modelo de <i>Bagging</i>	93
4.10	Matriz de Confusão para o modelo de <i>Random Forest</i>	93
4.11	Resultado em termos percentuais de todos os modelos aplicados às 13.300 empresas. O Erro do Tipo I representa a parte de empresas falidas que foram previstas como não-falidas, enquanto o Erro do Tipo II é o total de empresas não falidas que foram preditas como falidas. AUC é a área sob a curva <i>ROC</i> e ACC é a precisão total estimada.	93
4.12	As previsões dos modelos aplicados usando as variáveis do modelo popular de Altman (1968). Todos os métodos mostram perda de previsibilidade, sensibilidade e especificidade. Isso mostra a importância de incluir novas variáveis nos modelos.	95

Lista de Abreviaturas e Siglas

Código	Significado
ACC	Acurácia
ANN	<i>Artificial Neural Networks</i> ou Redes Neurais Artificiais
AUC	Área Sob a Curva <i>ROC</i>
CART	Árvores de Regressão e Classificação
CDO	<i>Collateralized Debt Obligation</i>
CDS	<i>Credit Default Swap</i>
CPB	Incremento na taxa <i>price-to-book</i>
CROE	Incremento no Retorno sobre o Patrimônio Líquido
CSFB	<i>Credit Suisse First Boston</i>
DOI	<i>Document Object Identifier</i>
EAD	<i>Loss Given Default</i>
EC	Capital Econômico
EL	<i>Expected Loss</i> ou Perdas Esperadas
GA	<i>Growth of Assets</i> ou Crescimento dos Ativos
GE	<i>Growth of Employees</i> ou Crescimento do número de funcionários
GQC	Quantidade Total de Citações
GS	<i>Growth of Sales</i> ou Crescimento das Vendas
IRB	<i>Internal risk-based</i>
JEL	<i>Journal of Economic Literature</i>
LGD	<i>Loss Given Default</i> ou Perda dada a Inadimplência
MDA	Análise Discriminante Multivariada
NLC	Número de Citações Locais
NYU	<i>New York University</i>
OM	Margem Operacional
PD	<i>Probability of Default</i> ou Probabilidade de Inadimplência
RBF	Função de Base Radial
ROC	Curva de Operação do Receptor
SSRN	<i>Social Science Research Network</i>
SVM	Máquina de Vetor de Suporte
UL	<i>Unexpected Loss</i> ou Perdas Inesperadas

1 Introdução

A inadimplência pode ser vista como uma das questões mais relevantes quando se estuda a situação financeira de um agente. Como se trata de um fenômeno decorrente de ação humana, a sua estimativa é algo com uma certa medida de incerteza. Se for levado em consideração que existe a possibilidade de se errar essa medida, de modo que seu resultado leve a algum dano ou perda para outro agente (contraparte), tem-se então uma situação de risco, ou melhor, o risco de inadimplência, melhor definido por risco de crédito.

O domínio cada vez maior desse risco por parte de Bancos, grandes corporações, investidores, praticantes do mercado financeiro e, claramente, pesquisadores em Finanças pode ser visto em diversas fontes: dados de balanço das empresas, projetos de investimentos corporativos, pesquisas científicas, análises econômicas, agências de classificação de risco, entre outras.

Um evento que contribui para colocar a gestão do risco de crédito na pauta de discussões de toda a sociedade é a crise financeira. A última delas, considerada de fato no final de 2007 com maior repercussão e evidências em 2008, trouxe a tona novamente a ideia de que esse risco deve ser avaliado e reavaliado constantemente, pois tem papel fundamental no resultado das empresas, sejam elas do ramo financeiro ou não.

Para tanto, os acordos da Basileia receberam o devido destaque por parte dos profissionais do setor bancário, com o intuito de notificar as pessoas no mundo todo que existe uma preocupação com o futuro do mercado financeiro global e suas perspectivas em relação a sua contribuição para o desenvolvimento social e econômico.

De acordo com [Evanoff et al. \(2011\)](#), a crise financeira expôs as deficiências subjacentes à supervisão bancária atual. O crescimento do tamanho e da complexidade dos bancos torna cada vez mais difícil para os reguladores para monitorar e permitir a tomada de riscos excessivos dos bancos por meio de mecanismos tradicionais de controle. Projetos políticos, como o regime de seguro de depósito e a tese “*Too Big Too Fail*” têm sido destacados pela ajuda de órgãos governamentais nos últimos anos, o que agrava ainda mais a situação. Isto levou a reacender o interesse na reforma da regulação bancária.

Num contexto histórico, estudos de crédito têm não somente uma importância prática, uma vez que está conectado a operações nas quais seres humanos vêm desempenhando durante séculos, mas também tem sua relevância teórica devido a sua relação com muitos outros estudos que articulam na base da teoria de finanças. Atualmente existem muitos interessados em aprofundar seus conhecimentos tanto na mensuração como na análise desse risco e de suas fontes de informação. Desde a segunda metade do século

passado, pesquisadores notaram a importância de se estudar eventos de inadimplência, com destaque para o estudo seminal de Altman (1968) que verificou aspectos relevantes para diagnosticar falência de empresas manufatureiras. Enquanto isso, ocorreram grandes contribuições que estiveram envolvidas com inadimplência como, por exemplo, Modigliani e Miller (1958), o qual é considerado um resultado fundamental para o campo de estudo em finanças e bastante discutido até os dias de hoje.

A gestão de riscos também tem se desenvolvido em diversos setores de atividade. O principal objetivo deste crescimento tem sido a necessidade por administrar melhor os riscos envolvidos no negócio, além de buscar soluções para minimizar seus efeitos nos resultados financeiros e operacionais, por meio de modelagem matemática avançada como também utilizando ferramentas estatísticas cada vez mais sofisticadas. Neste contexto, é importante lembrar que os modelos de risco de crédito baseiam-se na utilização de três variáveis: a probabilidade de inadimplência (*Probability of Default, PD*), a perda em caso de inadimplência (*Loss Given Default, LGD*), e a exposição à inadimplência (*Exposure at Default, EAD*). O acordo de Basileia II sugere um modelo que se aplica essas medidas para determinar as perdas esperadas e, como consequência, o capital econômico (ou regulatório). Muitas vezes, tais dados são difíceis de se conseguir, mas alguns estudos têm obtido-os por meio de relatórios das agências de *rating* (SUNDMACHER; ELLIS, 2011).

Seguindo a tendência de pesquisas em risco de crédito, esta tese foi elaborada no formato de três ensaios com foco em risco de crédito e na modelagem matemática envolvida em sua mensuração. Para validar teoricamente as pesquisas aqui desenvolvidas, realizou-se uma busca completa de trabalhos científicos sobre risco de crédito. Num primeiro momento constatou-se que mais de 3000 artigos sobre gestão de risco têm sido publicados e indexados em serviços de pesquisa acadêmicas, como *Scopus* e *Web of Knowledge*. Este nível de pesquisa destaca a importância e o desafio deste tópico.

Apesar de observar que a pesquisa sobre a gestão de risco está se movendo para preencher lacunas de conhecimento e mostrando novos *insights* sobre economia financeira, o grande número de trabalhos tem um lado negativo. Jovens acadêmicos, pesquisadores e alunos têm dificuldade em construir uma base concisa e abrangente dos conhecimentos que permite que novas lacunas sejam encontradas, em vez de abordar questões já resolvidas ou de menor importância.

Nesse sentido, a primeira contribuição deste trabalho é apresentar uma revisão sistemática da literatura sobre risco de crédito para artigos publicados desde 2000. Para atingir esse objetivo, os principais estudos sobre o risco de crédito foram classificados e codificados, e uma abordagem baseada em citação foi usada para determinar a sua relevância e as contribuições para o estado da arte. Dessa forma, identificaram-se algumas lacunas e recomendações de pesquisas, além de se encontrar oportunidades para estudos futuros.

Na sequência, a segunda contribuição importante deste trabalho é uma análise sobre o capital regulatório. Seguindo o método aplicado por [Sundmacher e Ellis \(2011\)](#), apresenta-se uma discussão de como os bancos podem melhorar as suas próprias avaliações com base em classificações de risco dos mutuários. Para isso, assume-se que LGD é dada por uma distribuição beta. Usando PD fornecida por uma agência de *rating* e LGD da [Society of Actuaries \(2002\)](#), [Society of Actuaries \(2006\)](#), as simulações mostram que o uso de classificações de risco na orientação para calcular os requisitos mínimos de capital pode ser uma alternativa para os bancos. Ainda, descobriu-se que é possível obter melhores classificações ao emprestar a empresas em alguns pequenos intervalos de LGD .

Por fim, a terceira e última contribuição baseia-se na previsão de falências por meio de técnicas computacionais de aprendizagem de máquina. Houve interesse de pesquisa intensiva durante várias décadas para desenvolver modelos de previsões de falência e de eventos de *default* como ferramentas para a gestão de risco de crédito. O Acordo de Basileia II (2004) encorajou e até mesmo forçou bancos e gestores de risco a desenvolverem modelos para melhor medir o risco de crédito. Pesquisas acadêmicas têm geralmente avaliado modelos de falência usando análise discriminante, a partir de [Altman \(1968\)](#); regressão logística (e.g., [OHLSON, 1980](#)); e a forma de inteligência artificial mais conhecida, as redes neurais.

A modelagem foi construída para testar alguns modelos de aprendizado de máquina (máquinas de vetores de suporte, *bagging*, *boosting* e *random forest*) para prever a falência.

Aplicando dados referentes a 1985–2013 de empresas norte-americanas, é feito um comparativo dos resultados destes métodos inovadores com redes neurais, regressão logística e análise discriminante. O grande resultado desta parte do estudo é uma melhoria substancial no poder de predição usando técnicas de aprendizado de máquina, quando, além das variáveis originais do Z -Score de [Altman \(1968\)](#), incluem-se seis métricas (ou constructos) selecionados a partir de [Carton e Hofer \(2006\)](#) como variáveis explicativas. A análise mostra que os modelos de *bagging*, *boosting*, e *random forest* aleatórios superaram as outras técnicas; e todas as previsões são melhoradas quando os constructos sugeridos são incluídos na pesquisa.

As razões para desenvolver este trabalho estão baseadas em alguns pontos relevantes da área de finanças: (i) A relevância do risco de crédito para as empresas, principalmente do ramo financeiro, tem sido crescente; (ii) existem algumas lacunas de conhecimento muito interessantes a serem exploradas em termos de pesquisas teóricas e também na aplicação de modelos computacionais na análise de riscos, que foram constatados na realização da revisão da literatura apresentada no próximo capítulo; (iii) a previsão de eventos de inadimplência é uma necessidade eterna, uma vez que os modelos atuais possuem precisão razoável, além da questão das variáveis envolvidas não serem consideradas ainda uma unanimidade, pelo menos no âmbito acadêmico. Dessa forma,

acredita-se que os resultados encontrados e os métodos empregados enriquecem a ciência e ainda trazem a tona novas possibilidades de pesquisas.

Este material está organizado da seguinte forma: o Capítulo 2 descreve uma ampla revisão da literatura envolvendo risco de crédito em diferentes direções. O Capítulo 3 analisa requisitos de capital e alternativas para as instituições financeiras para melhorar as suas classificações de crédito. Depois disso, uma análise comparativa das técnicas de aprendizado de máquina e ferramentas tradicionais de previsão de falências é feito no Capítulo 4. Finalmente, no capítulo 5, apresentam-se as observações finais.

2 Revisão da Literatura

A literatura econômica destaca de maneira incontestável que os seus agentes gastam parte de sua renda com o consumo. Embora esse processo pareça muito simples e de pouca importância para o sistema econômico como um todo, o mesmo não é, pois muitas vezes os agentes econômicos, principalmente as famílias, não pagam pelo seu consumo à vista, ou seja, elas utilizam o crédito. Em meio a esse processo, surgem as instituições financeiras que fornecem o crédito aos agentes econômicos (Famílias) acreditando que receberam o mesmo mais um adicional por disponibilizar essa importância e emprestam este capital a outros agentes econômicos (Empresas), para que as mesmas possam expandir seus negócios. A gestão dessa situação ou do risco pela oferta de crédito é muito complexa e delicada (CROUHY et al., 2000), pois o não cumprimento dos termos acordados na operação de crédito afetará todos os envolvidos e, principalmente, as instituições financeiras.

Razões para se estudar risco de crédito não faltam. Caouette et al. (2008) alertam sobre o crescimento desse risco e relembram alguns acontecimentos no mercado de crédito promoveram o crescimento de pesquisas envolvendo essa questão, como é o caso dos novos acordos da Basileia, a sofisticação dos participantes deste mercado, o aumento da oferta de derivativos de crédito e, por último, mas não menos importante, o surgimento de fundos de *hedge*.

Observando esse contexto, os acordos da Basileia II e III têm destacado a participação do risco de crédito na gestão de riscos dentro das instituições financeiras o que, por sua vez, intensificou a busca por modelos mais sofisticados e robustos para medir risco de crédito, justamente porque o capital econômico exerce forte influência no retorno dos bancos (ALTMAN; SABATO, 2007; TIAN et al., 2012).

A literatura a respeito de risco de crédito segue a mesma tendência dos agentes ligados ao assunto, isto é, está em expansão nos últimos anos (CHAVA; PURNANANDAM, 2010; JORION; ZHANG, 2007). Em comparação a outros riscos como o operacional, o risco de mercado e o risco de liquidez, o número de publicações aponta para uma ampliação crescente de estudos sobre o tema em uma perspectiva global, conforme apresentado na Figura 2.1.

Como consequência desse processo, a proposição de novas ferramentas, técnicas, e modelos para mensurar e prever o risco de crédito também aumentou e, atualmente, esse conjunto compreende desde técnicas matemáticas e estatísticas como simulações (MORELLEC, 2003; HACKBARTH et al., 2006; BATTISTON et al., 2012); tratamento econométrico (ANGELINI et al., 2008; DEYOUNG et al., 2008; EVANOFF

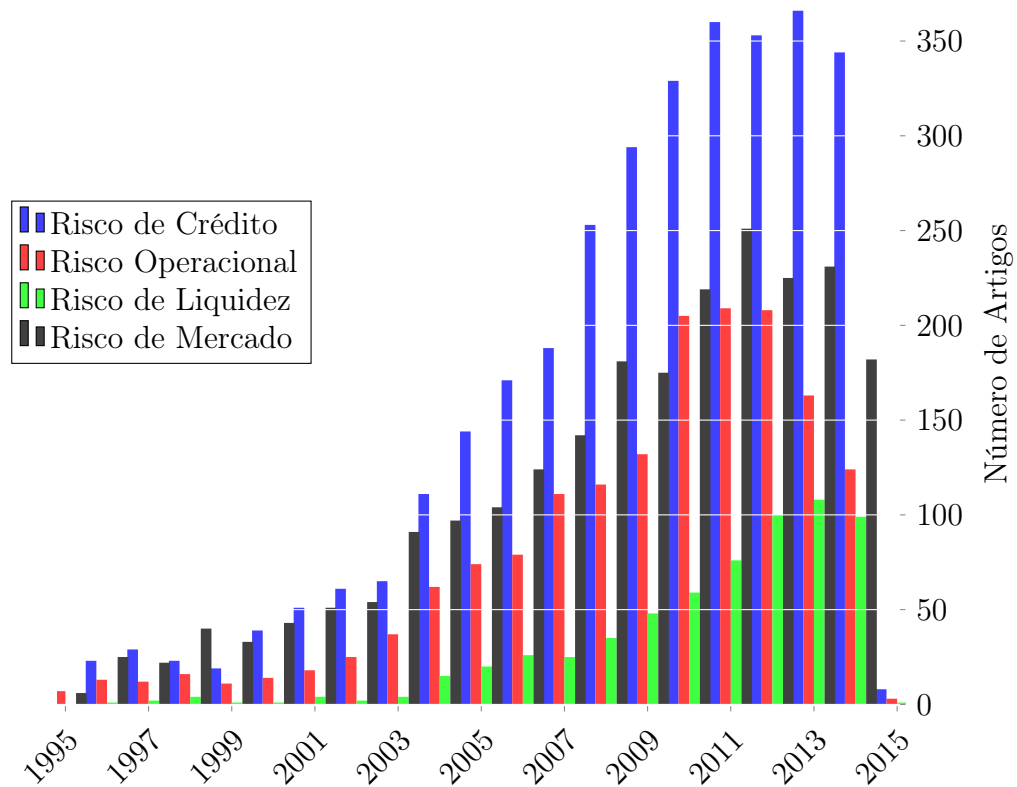


Figura 2.1: Quantidade de estudos publicados sobre gestão de riscos que forma indexados as principais base de dados acadêmicas. Fonte de dados: *Web of Science*.

et al., 2011; GRIFFIN; TANG, 2012; JIMÉNEZ et al., 2014) e estatística multivariada (GEORGE; HWANG, 2010; EOM et al., 2003; GORDY; HOWELLS, 2006; VERONESI; ZINGALES, 2010; ALTMAN; SABATO, 2007), passando por processos de otimização (BIELECKI et al., 2005) chegando até as aplicações de teorias mais recentes e sofisticadas como a utilização de cópulas para medir correlação, conforme apresentado no trabalho de (ROSENBERG; SCHUERMANN, 2006).

Para aqueles que começam a estudar risco de crédito é difícil separar ou identificar quais trabalhos constituem a pedra fundamental ou o *framework* e, principalmente, quais *gaps* devem ser observados nessa área de conhecimento, em meio a tantas ideias, inovações, modelos e comprovações empíricas. Com base nessa situação problema, esta tese apresenta uma revisão sistemática da literatura a respeito de risco de crédito e seus componentes na tentativa de mostrar os avanços, produzidos no âmbito acadêmico que tiveram destaque nos últimos 15 anos, e os *gaps* que ainda permanecem ou surgiram recentemente.

Elyasiani e Goldberg (2004) realizaram uma pesquisa sobre empréstimos e descobriram que é necessário mais investigação sobre este assunto. Allen (2004) também apresenta uma revisão da literatura a respeito dos mercados de hipotecas e da influência dos Acordos da Basileia I e II. Suas conclusões enfatizaram que temos muitos problemas para resolver sobre modelos de risco de crédito, requisitos de capital entre outros temas.

Recentemente, [Alhashel \(2015\)](#) forneceu um quadro histórico e discutido sobre os fundos soberanos, a fim de fazer uma revisão sobre o tema.

Em suma, não é possível encontrar qualquer revisão sistemática relacionada ao risco de crédito ou assuntos análogos nos últimos 15 anos. É importante destacar que a revisão sistemática permite a imposição de limites a este trabalho, uma vez que risco de crédito é um assunto muito abrangente e existe uma grande quantidade de estudos nessa área. Por outro lado, como bem destaca [Jabbour \(2013\)](#), a realização de uma revisão sistemática da literatura permite integrar ou identificar estudos sobre assuntos emergentes dentro de uma determinada área de conhecimento como, por exemplo, risco de crédito.

Visando cumprir o objetivo aqui delimitado, na próxima seção será apresentado o método de pesquisa utilizado. De maneira breve: na Seção 2.1, demonstra-se os resultados fundamentais sobre risco de crédito; descreve-se a metodologia na Seção 2.2; na Seção 2.3, mostra-se a classificação e codificação utilizada; os principais resultados são indicados na Seção 2.4; por fim, na Seção 2.5 é feita uma discussão sobre as principais conclusões, limitações e propostas de trabalhos futuros.

2.1 Uma Breve Descrição Conceitual sobre Risco de Crédito

A atividade bancária vem sendo desenvolvida há muito tempo. De acordo com [Hoggson \(1926\)](#), há evidências de que no vale da Mesopotâmia, as leis de Hamurabi, que datam de 2000 AC, já regulavam o uso da água, aos aluguéis da terra, à comissão de agentes, às dívidas e aos juros. Portanto, nesse contexto prático, a existência de regras em relação a empréstimos sugere a necessidade de estabelecimento de mecanismos para a gestão do risco de crédito, mais particularmente, para mitigar riscos de *default*.

No contexto de conhecimento científico, pode-se argumentar que a modelagem de crédito é contemplada desde as origens da teoria de finanças. O trabalho seminal de [Modigliani e Miller \(1958\)](#) possui uma ligação com a análise de crédito, uma vez que uma estrutura de capital formada por recursos próprios e capital de terceiros induz a um risco de não-pagamento da dívida e, portanto, à existência de uma probabilidade de *default* (*PD*).

Ainda exemplificando a forte ligação de elementos de crédito com trabalhos fundamentais de finanças corporativas e investimentos, é importante destacar que a estrutura de capital induz problemas de agência ([JENSEN; MECKLING, 1976](#)) entre acionista e credor bem como dá sustentação para a avaliação de ações e de dívida a partir da lógica de precificação de opções [Merton \(1974\)](#).

De acordo com [Jarrow e Protter \(2004\)](#), em particular, os estudos de [Black e Scholes \(1973\)](#) e de [Merton \(1974\)](#) conferem bases a uma das principais classes de modelos de risco de crédito: a abordagem estrutural, por meio da qual as dívidas corporativas apresentam cláusulas de opções sobre os ativos da empresa ([GIESECKE, 2004](#)). De forma complementar, a segunda classe de modelos de crédito é mais recente, com origens nos trabalhos de [Artzner e Delbaen \(1995\)](#), [Jarrow e Turnbull \(1995\)](#) e [Duffie e Singleton \(1999\)](#) e leva em consideração que o *default* ocorre com uma intensidade calibrada por meio de preços de mercado, de forma exógena ([GIESECKE, 2004](#)).

Assim, sob o contexto histórico, o estudo de crédito possui não somente uma relevância prática, por estar ligado a operações que indivíduos já vinham realizando há séculos, como também importância teórica, por ter conexão com diversos trabalhos que fundamentam a teoria de finanças.

Considerando mais especificamente aspectos relacionados diretamente com análise de crédito, os trabalhos de [Beaver \(1966\)](#) e [Altman \(1968\)](#) representam marcos teóricos que lançam bases para uma série de pesquisas que envolvem o desenvolvimento de modelos de previsão de *default* e falências.

Enquanto [Beaver \(1966\)](#) conduziu uma análise univariada para identificar índices financeiros que poderiam ajudar a prever empresas que “falham” das que “não falham”, [Altman \(1968\)](#) realiza uma análise multivariada, adaptando o uso de uma técnica de classificação, a análise discriminante, para cálculo de um escore associado ao risco de falência de empresas do setor de manufatura americano com ações publicamente disponíveis.

O trabalho seminal de [Altman \(1968\)](#) teve grande repercussão, permanecendo bastante popular na literatura ([BELLOVARY et al., 2007](#)) e sendo adaptado a outros setores e contextos. Por exemplo, [Edmister \(1972\)](#) investigou o risco de falência de pequenas empresas e [Sinkey \(1975\)](#) analisou falência de instituições financeiras. [Taffler \(1984\)](#) desenvolveu modelos para vários tipos de empresas do Reino Unido e ([ALTMAN et al., 2005](#)) discutem resultados de modelagem de risco para empresas não-manufatureiras e para créditos de mercados emergentes.

Embora o poder preditivo de modelos baseados em estatística multivariada como os de [Altman \(1968\)](#) e de [Ohlson \(1980\)](#) tenha diminuído ([BEGLEY et al., 1996](#)), mais recentemente técnicas de inteligência artificial e de aprendizagem de máquina têm representado nova linha de pesquisa na área de risco de crédito, mais especificamente para a previsão de falência. Por exemplo, [Galindo e Tamayo \(2000\)](#) estudam 9000 modelos de avaliação de risco de crédito por meio de técnicas estatísticas e de aprendizagem de máquina como, por exemplo, redes neurais, CART (*Classification and Regression Trees*) e o algoritmo do K-ésimo vizinho mais próximo. [Khandani et al. \(2010\)](#) analisam crédito ao consumidor usando CART para aprimorar classificação de titulares de cartões de crédito.

Outra linha de pesquisa em análise de crédito envolve modelagem de risco

que foram desenvolvidos a partir de exigências provenientes da regulamentação bancária, notadamente, em função das diretrizes da Basileia. Nesse contexto, trabalhos ligados a modelos utilizados por praticantes do mercado como, por exemplo, KMV de probabilidade de *default*, descrito em [Crosbie e Bohn \(2002\)](#), *CreditMetrics* ([GUPTON et al., 2007](#)), *CreditRisk+* ([CSFB, 1997](#)) e *CreditPortfolioView* ([WILSON, 1997a](#); [WILSON, 1997b](#)), também foram tema de pesquisas no âmbito científico.

Pesquisas mais recentes, impulsionadas pela regulamentação envolvem avaliação e prevenção de crises sistêmicas e, dentro do contexto de crédito, mecanismos de avaliação do risco de crédito da contraparte têm sido estudados. Mais particularmente, as necessidades de regulamentação exemplificadas no documento do *Bank of International Settlements* (2012) têm impulsionado linhas de pesquisa em termos de ajustes na avaliação de crédito, principalmente em operações com derivativos.

Embora não extensiva, a lista de temas pode ser complementada por estudos que analisam *spread* de crédito (e.g. [FORTE; PEÑA, 2009](#)) e a operações que, de certa forma, estão baseadas em transações ou risco de crédito como, por exemplo, securitização (e.g., [GREENBAUM; THAKOR, 1987](#)) ou derivativos de crédito (e.g., [NORDEN; WAGNER, 2008](#)). Estudos sobre falência e finanças corporativas também são extensos com uma diversidade de interligações. Por exemplo, [George e Hwang \(2010\)](#) investigam *puzzles* de risco de falência e alavancagem enquanto Berk, Stanton e Zechner (2010) analisam capital humano, estrutura de capital e risco de falência.

2.2 Método de Pesquisa

A busca de fontes ou estudos no tocante ao tema iniciou-se no ano 2000 e finalizou em dezembro de 2014. Este período foi escolhido devido a sua representatividade em relação ao número de publicações sobre a temática gestão de risco, isto é, o assunto risco de crédito compreende a 97,5% dos estudos publicados nesses anos. Embora esse fato ou apontamento seja interessante, ele já tinha sido previamente visualizado e destacado no trabalho de [Caouette et al. \(2008\)](#). Ainda nessa perspectiva, visando corroborar com essa afirmação, a Figura 2.2 ilustra o resultado de uma simples pesquisa considerando o termo “*Credit Risk*” como palavras-chave, na base acadêmica *Scopus*.

De maneira mais precisa, no tocante aos dados utilizados nesse trabalho, o levantamento dos mesmos foi realizado considerando as três seguintes bases:

1. *Proquest*;
2. *Scopus* (em consonância com a *Science Direct*); e
3. *Web of Science Core Collection*.

A escolha dessas bases acadêmicas considerou principalmente a abrangência informações bibliométricas fornecidas, isto é, as mesmas contemplam um vasto volume de




Figura 2.2: Número de artigos encontrados na busca feita na base de dados da *Scopus* usando a palavra-chave “*Credit Risk*”.

trabalhos publicado por diversas editoras como, por exemplo, *Elsevier*, *JSTOR*, *Springer*, *Taylor & Francis*, *Emerald*, e *Wiley* e fornecem dados a respeito do número de citações de cada trabalho. Consequentemente, esta pesquisa foi realizada pela execução das seguintes etapas, a saber:

Etapa 1: Análise dos pontos positivos e negativos das bases de dados: nesse processo foram considerados a abrangência, o período total de captação de dados, a forma de busca (simples e avançada), a clareza nas informações fornecidas e a inconsistências dos motores de busca. Esse processo foi realizado visando identificar que o mesmo padrão de busca fosse executado de maneira idêntica em todas as bases;

Etapa 2: Realização da pesquisa considerando o seguinte padrão:

- As Palavras-Chave: “*Credit Risk*”, “*Probability of Default*”, and “*Bankruptcy*”;
- Filtro de idioma: *English*;
- Áreas de concentração: *Business, Economics, and Finance*;
- Tipo de material: *Article*;
- Fonte: *Scholarly Journals*; e
- Período compreendido: Janeiro de 2000 a Dezembro de 2014.

- Etapa 3:** Seleção dos artigos mais citados: nessa etapa, com o objetivo de delimitar o número de trabalhos a serem considerados, os artigos foram ordenados com base nas citações, pois dessa forma os artigos publicados nos primeiros anos do período considerado (Janeiro de 2000 até dezembro de 2014) que não receberam citações foram excluídos;
- Etapa 4:** *Download* dos artigos e criação da base de dado: Considerando os resultados da Etapa 3, todos os artigos foram baixados e as informações básicas de cada artigo como, por exemplo, título, nome dos autores, ano de publicação, nome de *publisher*, nome do *journal*, palavras-chave, classificação *Journal of Economic Literature* (JEL), endereço de registro (conhecido por *Digital Object Identifier*, DOI), e número de citações foram coletadas, visando criar a base de dados;
- Etapa 5:** Realizando a estatística descritiva: considerando os dados da base criada na Etapa 4, foi realizada uma análise descritiva dos dados, visando identificar informações, padrões e lacunas;
- Etapa 6:** Leitura e codificação dos artigos: todos os artigos foram lidos com propósito de identificar o objetivo, o resultado e a contribuição de cada um na área de risco de crédito. Além disso, cada artigo foi classificado e codificado, conforme descrito na Seção 2.3.

2.3 Critérios de Classificação e Codificação

O processo de classificação constitui um dos pontos mais importantes dessa sistematização, pois é nessa etapa em que são identificadas as principais características presentes nos artigos revisados e considerados na base criada na Etapa 3. É importante destacar que a essa sistematização de literatura ou melhor a classificação e codificação dos artigos foi realizada com base no trabalho de Lage Junior e Godinho Filho (2010), Jabbour (2013) e Seuring (2013). Sendo assim, inicialmente, identificou-se os seguintes dados de cada estudo:

- Título;
- Autores;
- Instituição do(s) autor(es);
- País de origem do autor ou da instituição. É válido destacar que a fonte desse dado é o endereço disponível no artigo;
- Ano de publicação;
- Nome do periódico;
- Volume, número da edição, página final e inicial. Essas informações foram coletadas visando identificar se houveram edições especiais sobre o tema risco de crédito em algum periódico;
- Origem e intervalo de tempo considerado nos dados utilizados em cada estudo;

- Palavras-chave;
- Classificação do artigo no sistema JEL (*Journal of Economic Literature*);
- Número de citações que o artigo tem nas bases *Scopus* e *Web of Science*; e
- Referência *Digital Object Identifier* (DOI).

É muito importante destacar que alguns desses dados necessitaram de maior cuidado no levantamento. Nesse sentido, os seguintes cuidados foram tomados:

- No caso do autor trabalhar em mais de uma instituição, foi identificada apenas a instituição mais importante, por ordem dos seguintes critérios:
 - O endereço eletrônico considerado do principal autor;
 - A primeira instituição nomeada pelo autor; e
 - A localização atual, caso nenhuma das condições anteriores for atendidas.
- Com relação às palavras-chave, nem todos artigos apresentam as mesmas, o que levou a uma busca desses dados em outras fontes. Para isso, por ordem de importância, foi necessário considerar alternativas, a saber:
 - Buscou-se primeiramente uma versão do trabalho no banco de *working papers* denominado *Social Science Research Network* (SSRN), o qual forneceu boa parte das palavras-chave dos artigos, por exemplo, publicado no *The Journal of Finance*; e
 - A pesquisa prosseguiu pela base *Web of Science Plus*, a qual possui uma ferramenta chamada *Keyword Plus* capaz de fornecer palavras-chave por meio de uma seleção de palavras que ocorrem com maior frequência nos títulos de trabalho mais citados e de tema semelhante, caso não fosse identificado uma versão do artigo na base SSRN.

Após essa primeira coleta de dados, 17 artigos foram identificados fora de contexto ou não relacionado com o tema “Risco de Crédito” e, conseqüentemente, esses artigos foram excluídos da base de dados. Considerando os artigos restantes, nove categorias de classificação foram definidas. Além disso, para cada uma dessas categorias foram estabelecidas subcategorias ou códigos, visando especificar a localização do artigo no que diz respeito a uma determinada categoria, conforme apresentado na Tabela 2.1.

A primeira categoria, ou seja, o item “Tema Principal” tem como propósito identificar o tema e qual assunto foi considerado como subcategoria. Nesse sentido, as seguintes subcategorias foram consideradas:

- Gestão de Risco: nessa subcategoria são atribuídos os artigos que estudam o risco de maneira mais abrangente ou geral, com foco na gestão;

Categoria	Significado	Código para cada alternativa
1	Tema Principal	A - Gestão de Riscos B - Modelagem em Risco de Crédito C - Análise de <i>Ratings</i> D - Previsões E - Derivativos de Crédito F - Outros
2	Método	A - Abordagem Teórica B - Análise de Séries Temporais C - Análise Multivariada D - Simulação e Método Computacional E - Estudo Empírico (estudos de caso ou similar) F - Outros
3	Origem de Dados	A - Instituições Financeiras B - Empresas (dados de balanço) C - Títulos D - Derivativos E - Macroeconômica F - Outros
4	Local de Origem dos Dados	A - EUA B - Europa C - Ásia D - Global, outro ou não mencionado
5	Variável de Interesse	A - Capital Econômico ou Perdas B - <i>Pricing</i> C - PD D - LGD E - Outros
6	Hipóteses/Objetivos	A - Um ou não mencionado B - Dois C - Três D - Quatro ou mais
7	Implicações	A - Novas Perspectivas B - Consistente com outro(s) estudo(s) C - Modelo conhecido e/ou outros dados (fontes) D - Comparações E - Outros
8	Área de Estudo (JEL)	A - G10 or G1 B - G20 C - G30 D - Outros E - Não mencionado ou indisponível
9	Período de análise	A - Menos de 3 anos B - Entre 3 e 5 anos C - Entre 6 e 10 anos D - Mais de 10 anos E - Não aplicável

Tabela 2.1: Categorias e Códigos aplicados neste estudo com os respectivos significados.

- Modelos de Risco de Crédito: nessa subcategoria, os autores estão preocupados com questões de modelagem das variáveis de risco de crédito;
- Análise de *Ratings*: nessa subcategoria são observados os trabalhos com foco na qualidade creditícia de qualquer natureza e que direciona a pesquisa para uma avaliação ou crítica à categoria, seus atributos, critérios e considerações. Notadamente, os modelos de previsão e a gestão de risco estarão presentes, mas não ocupam posição mais importante do que a categoria. No caso das previsões, deve-se notar a diferença para as outras classificações. Considerando que a categoria é “Tema Principal”, observa-se que quase todos os trabalhos possuem algum tipo de previsão, no entanto esse aspecto, não qualifica os mesmos na subcategoria D. Em outras palavras, ao observar que o tema é melhor classificado como gestão de risco ou modelo de risco de crédito ou *rating*, esta qualificação é ignorada, porém se houver forte influência, por exemplo, de tratamento econométrico e estatístico para previsibilidade e tal objetivo compete com as outras classificações, o trabalho é classificado em ambas;
- Derivativos de Crédito: nessa subcategoria são contemplados os estudos que envolvam derivativos como “*Credit Default Swap*” (CDS) e “*Collateralized Debt Obligation*” (CDO); e
- Outros: nessa subcategoria serão considerados estudos cujos temas principais não tiveram afinidade com nenhuma das opções anteriores.

Na segunda categoria identificou-se o principal método aplicado ou utilizado pelos autores em seus estudos. São seis opções - uma das categorias mais abrangentes - podendo o artigo estar em mais de uma categoria, assim como em todos os outros oito critérios investigados. Vale lembrar que o mais importante nesse quesito é o método associado ao tema principal, isto é, saber qual método foi empregado no foco do trabalho. Desse modo, por exemplo, estudos teóricos que utilizem uma pequena regressão ou técnica estatística em uma pequena parte do trabalho não foram considerados nessa subcategoria da pesquisa. Consequentemente, as subcategorias que compreendem essa categoria são:

- Abordagem Teórica: nessa subcategoria os estudos procuram contribuir de maneira direta como arcabouço teórico da área ou, em outras palavras, esses artigos têm como preocupação central criticar ou complementar os aspectos conceituais. É importante destacar que esses *papers*, às vezes, utilizam sofisticadas ferramentas ou abstrações matemáticas;
- Análise de Séries Temporais: nessa segunda subcategoria, os estudos têm como principal característica a realização de análise de regressões, apresentando testes estatísticos de robustez e, caso necessário, outros elementos de análise relevantes para a validade da pesquisa em si;

- Análise Multivariada: nessa subcategoria são considerados os trabalhos relacionados a pesquisas de um fenômeno por meio de técnicas estatísticas que não se encaixam numa série de tempo, como é o caso de probabilidades e correlações;
- Simulação e Método Computacional: essa subcategoria visa compreender os artigos que abrangem técnicas de simulação computacional mais contemporâneas em dados empíricos como, por exemplo, os artigos que apresentam a utilização de técnicas baseadas em aprendizagem de máquinas; e
- Estudo Empírico: nessa categoria são considerados os artigos que abordam fenômenos evidenciados por ocorrência de um pequeno número de elementos amostrais, como estudos de caso ou amostras representadas por exceções de uma determinada assumpção em uma população.

É importante destacar que os artigos que apresentam análise de dados em painel são classificados como “Análise de Séries Temporais”, assim como os artigos do tipo “Análise Multivariada” e “*Cross Sections*” (desde que feita uma análise ao longo do tempo) também adotariam os mesmos códigos.

A categoria denominada “Origem de Dados” é uma categoria bem objetiva, assim como a categoria “Área de Estudo (JEL)” e “Período de Análise”, e está separada pelo gênero dos dados considerados nos trabalhos, ou seja, saber qual a fonte de dados específica de que trata o trabalho. No caso de trabalhos teóricos, a fonte de dados foi selecionada considerando-se aquela mais indicada ou citada pelo autor como sugestão de aplicação, mesmo não sendo necessariamente a estudada. A mesma interpretação aplica-se aos estudos que realizam simulação. Novamente, a consideração de dados bancários (capital econômico, modelos de risco, etc) e, simultaneamente, de outras organizações, classificam o estudo nas duas opções.

A localização geográfica na qual coletou-se os gráficos determinam a quarta categoria. Nesse caso, as fontes são bem claras nos trabalhos e geralmente são explicitadas em seções específicas. Nos casos de estudos que envolvem, além de EUA, países europeus e asiáticos, os mesmos foram classificados na quarta possibilidade.

A categoria de número cinco procura identificar a principal variável de interesse nos estudos. Tal categoria apresentou-se mais abrangente em alguns casos, justamente pelo fato do(s) autor(es) não enfatizar(em) nenhum de seus resultados. O caso da subcategoria *Pricing* aplica-se a estudos com foco em retorno de ativos, *spread* de derivativos, *valuation* e similares. Além disso, é válido destacar que a variável taxas de recuperação foi considerada na subcategoria LGD.

O número de hipóteses apresentou-se em muitos casos de forma visível, porém encontrou-se casos em que o(s) autor(es) apenas cita(m) seus objetivos, principalmente em análises de caráter comparativo.

A categoria denominada “Implicações” é uma parte muito bem explorada nos trabalhos. Assim, os autores são bem enfáticos em apresentar a inovação dos seus estudos no artigo. De maneira geral, essa categoria procurou identificar qual é a relação dos estudos mais recentes com os estudos previamente apresentados. Conseqüentemente, as suas subcategorias são auto explicativas.

A categoria ou classificação JEL foi coletada e simplesmente apurada de acordo a sua disponibilidade nos próprios artigos. É importante frisar que em 11 estudos não foram encontrados classificação JEL e optou-se nesta pesquisa por não buscar similares.

Finalmente, a última categoria considerada nesta tese, procurou identificar o período de abrangência dos dados e, conseqüentemente, foi separado em quatro classes de tamanhos distintos. Não houve nenhum tratamento quantitativo nesses dados para evitar tendências e erros de proporção nas análises.

2.4 Resultados e Discussão

A pesquisa nos motores de busca identificou mais de 3 mil trabalhos científicos, durante o período de abrangência (2000 a 2014). Diante da inviabilidade de se estudar tanto material, fez-se necessária uma seleção objetiva. Conseqüentemente, além dos filtros já previamente definidos na busca, outros critérios objetivos foram considerados. O primeiro foi verificar o número de citações por ano, desde a sua publicação, e analisar somente aqueles com uma média anual de, no mínimo, cinco citações. Com esse corte, artigos recentes não são excluídos, *outliers* (potencialmente artigos seminais) permanecem sem qualquer prejuízo e trabalhos obsoletos, ou seja, que já foram referência, mas estão ultrapassados e/ou não contribuem efetivamente para o conhecimento são descartados. Aplicando tal critério nas três amostras obtidas o resultado foi reduzido para aproximadamente uma centena de artigos.

A partir deste ponto, prosseguiu-se com a classificação, coleta detalhada de informações e análise dos trabalhos. Durante essa fase mais alguns artigos foram excluídos por não possuir aderência ao tópico “Risco de Crédito” foco dessa revisão sistemática de literatura. A amostra final concentrou-se em 83 trabalhos.

No sentido de observar a origem das pesquisas e os principais colaboradores atualmente nessa área do conhecimento, verificou-se quais seriam os principais autores e as respectivas instituições com maior incidência na base de dados, conforme apresentado na Tabela 2.2 e na Tabela 2.3.

Com relação a localização, isto é, o país de onde surgiram as pesquisas a lista de resultados é menos extensa. A Tabela 2.4 resume os dados por ordem de importância e simultaneamente é exibido o total de autores independentemente de sua ordem no rol de autores.

Autor	Trabalhos	<i>h-index</i>	Citações (GQC)	Citações Locais (NLC)
Darrel Duffie	3	17	1992	18
Viral V. Acharya	2	17	1148	7
Stefano Battiston	2	4	125	0
Michael B. Gordy	2	6	390	5
John M. Griffin	2	7	140	5
J. Grunert	2	2	75	0
Robert A. Jarrow	2	8	212	5
Gabriel Jiménez	2	6	180	2
Phillip Jorion	2	10	382	3
Outros	1	NA	NA	87
Total	83	–	–	132

Tabela 2.2: Lista dos principais pesquisadores em ordem decrescente de quantidade de publicações no período de 2000 a 2014. **Fonte de dados:** *Web of Science*.

Instituição	Artigos
<i>New York University</i>	4
<i>University of California</i>	4
<i>University of Mannheim</i>	3
<i>Arizona State University</i>	2
<i>Bank for International Settlements</i>	2
<i>Board of Governors of the Federal Reserve System</i>	2
<i>Cornell University</i>	2
<i>ETH</i>	2
<i>London Business School</i>	2
<i>Massachusetts Institute of Technology</i>	2
<i>Stanford University</i>	2
<i>University of Chicago</i>	2
<i>University of Toronto</i>	2
<i>Washington University</i>	2
Total	33

Tabela 2.3: Quantidade de artigos publicados considerando a instituição de origem do principal autor.

Os principais periódicos que abordam o tema “Risco de Crédito” estão concentrados em quatro *top journals*, como exposto na Tabela 2.5. Entretanto, artigos de grande importância surgiram em outros periódicos como, por exemplo, o estudo de Hillegeist et al. (2004), Bielecki et al. (2005) e Ericsson et al. (2009), publicados em *Review of Accounting Studies*, *Mathematical Finance* e *Journal of Financial & Quantitative Analysis*, respectivamente. Nesse sentido, comparando tais *journals* que constam na Tabela 2.5, o total de citações no período de 2000 até 2015 pode ser visualizado na Figura 2.3. Ainda dentro dessa perspectiva, considerando os dados da base *Scopus*, o *Journal of Financial Economics* ocupa a posição de primeiro lugar enquanto periódico mais citado, mesmo não sendo o periódico com o maior número de artigos publicados a respeito do tema.

Na Tabela 2.6 e na Tabela 2.7 são apresentados os resultados da classificação

País	Posição (importância) do autor					Soma
	1	2	3	4	5	
EUA	46	44	20	6	2	118
Alemanha	6	5	2	0	0	13
Reino Unido	6	4	2	0	0	12
Canadá	5	4	2	0	0	11
Itália	2	5	4	0	0	11
China	4	3	1	1	0	9
Espanha	4	3	1	1	0	9
Suíça	5	1	1	0	0	7
Suécia	1	1	1	1	0	4
Grécia	1	1	1	0	0	3
Holanda	1	1	0	0	0	2
Singapura	0	1	1	0	0	2
Dinamarca	0	1	0	0	0	1
Israel	0	1	0	0	0	1
Paraguai	0	0	1	0	0	1
Portugal	1	0	0	0	0	1
Turquia	1	0	0	0	0	1
Total	83	75	37	9	2	206

Tabela 2.4: País de origem dos pesquisadores e as respectivas instituições em ordem de número de publicações.

<i>Journal</i>	Artigos Publicados	Total de Citações [†]
<i>Journal of Financial Economics</i>	15	183.113
<i>Journal of Finance</i>	16	138.219
<i>Econometrica</i>	3	72.928
<i>Journal of Banking & Finance</i>	22	62.768
<i>Review of Financial Studies</i>	10	47.061
<i>Journal of International Money & Finance</i>	2	25.054
Outros (com apenas um artigo publicado)	15	NC

Tabela 2.5: *Journals* ordenados de acordo com a representatividade de artigos na amostra. **Fonte de dados:** *Scopus, Web of Science e Proquest*. * NC significa Não Computado.

[†] A última coluna indica o total de citações de todos os artigos desde 2000 até 19 de dezembro de 2014.

dos artigos, considerando a categoria e subcategoria apresentada na Tabela 2.1, uma breve descrição do objetivo, conclusão e contribuição de cada trabalho para a área de risco de crédito.




Figura 2.3: Total de citações (em milhares) dos principais *journals* que possuem publicações aplicadas nesta pesquisa. **Fonte de dados:** *Scopus*.

Artigo	Tema	Método	Dados	Origem	Variável	Hipóteses	Implicações	JEL	Período
Crouhy et al. (2000)	B	E	A	E	F	A	D	A-B	E
Gordy (2000)	B	D-E	A	E	C	A-C	D	A-C-D	E
Huang et al. (2009)	A	B-C	A-D-E	A	B-C	B	A	A-B-D	C
Rosenberg e Schuermann (2006)	A	B-C-E	A	A	A	C	A-D	A-B-D	C
Chatterjee et al. (2007)	B	D	B	B	D	A	C	E	B
George e Hwang (2010)	F	A-C	B	A	F	D	A	C-D	D
Angelini et al. (2008)	F	A-B	B	A	F	D	A-D	A-C	D
Yu (2005)	B	A-C	B-C-D	A	B	B	B	A-D	D
Gopalan et al. (2007)	D	B-E	B	C-D	F	C	A	C	D
Errais et al. (2010)	B-E-F	A-C-E	D	A	F	A	A	D	D
Gross (2002)	B-D	B	F	A	C	B	C	B-C-D	A
Zhu (2006)	B-E-F	B-E	C-D-E	A-B-C	B	B	A-D	A	B
Amato e Furfine (2004)	C	B	B	A	F	B	C	B-C	D
Hillegeist et al. (2004)	B	B	A	A	C	A	C-D	A-D	D
Ivashina (2009)	F	B	A	A	B	A	A	B	D
Griffin e Lemmon (2002)	F	B	B	A	F	A	E	A	D
Morellec (2003)	F	A-C-D	F	E	F	A	A-B	A-C	E
Hackbarth et al. (2006)	A	A-C-D	B-F	E	B-F	A	A-B	A-C	E
Jiménez e Saurina (2004)	A-B	C	A	B	C	C	A	B	D
Das (2007)	A-B-D	B-C	B	A	C-F	D	A	A-C	D
Agarwal e Taffler (2008)	B-D	C-E	A	B	C-F	B	C-D	A-C-D	D
Bielecki et al. (2005)	A	A	F	E	F	A	A	E	E
Güntay e Hackbarth (2010)	D-E	B	C	A	F	B	A	A-C	D
Carling et al. (2007)	B-C	B	A-B-E	B	C	A	A-B-D	B-C-D	D
Jarrow e Yu (2001)	A-B-D	A	C-D	E	B	A	A-C	A	E
Battiston et al. (2007)	F	D	B	E	F	B	A	D	E
Jorion e Zhang (2009)	A-E	B	A-B-D-F	A	F	D	A-B-C	A-B-C	D
Bonfim (2009)	B-D	C	B-E	B	C	A	E	B-C-D	C
Allen e Carletti (2006)	A-D	D	A	E	F	B	B	B	E
Acharya et al. (2011)	A-F	B-C	B-E-F	E	F	D	A	C	D

(Continua)

Artigo	Tema	Método	Dados	Origem	Variável	Hipóteses	Implicações	JEL	Período
Battiston et al. (2012)	A	A	F	E	F	A	A	A-B-D	E
Vassalou e Xing (2004)	B-F	B	B	A	B-C	D	B-C	A-C	D
Griffin e Tang (2012)	C-E	B	D	E	B-F	C	A	E	D
Davydenko e Franks (2008)	A-F	B	B	B	F	C	D	B-C	D
Mansi et al. (2004)	A-E	B	B	A	B	A	B	C-D	D
Acharya et al. (2007)	B-D-E	B	B	A	D	D	A-B-C	A-C	D
Gropp et al. (2006)	A-C-D-E	C	A-D	B	B	C	D-E	A-B-D	D
Brissimis et al. (2008)	A-D-F	B	A	B	F	C	A-C	B-D	D
Poon (2003)	F	C	B	A-B-C	B	D	A	E	D
Maudos e Guevara (2004)	A-F	B	A	B	B	A	C	B-D	D
Bharath e Shumway (2008)	E	B	C	B	B	A	A	A	A
Duffie et al. (2009)	B-D	C	B	A	C	C	C-D	A-C	D
Jorion e Zhang (2007)	B-D-E	C	B	A	C	A	A	C-D	D
Jiménez et al. (2014)	A-E	B	D	A-E	B	C	B-C	A-C	B
Beber et al. (2007)	A-D-F	B	A	B	F	A	E	A-B-D	C
Hennessy e Whited (2007)	D-F	A-D	B	E	B	A	B-C	E	E
Campbell et al. (2008)	A-B-D	C	B	A	B-C	D	C-D	A	D
Jappelli e Pagano (2002)	A-D-F	B	A	E	F	A	E	B-D	A
Hertzel et al. (2008)	F	B	B	A	F	D	A	C	D
Chava e Purnanandam (2010)	A-D-F	B	B	A	B-C-F	A	C-E	A-B-C	D
Foos et al. (2010)	A	B	A	E	F	C	A	B	D
Chen (2010)	B-E	A	B-E	E	A-B	A	A	A-C-D	E
Tang e Yan (2010)	E	B-E	D-E	A	F	C	A	A-D	C
Altman e Sabato (2007)	B-D	C	B	A	C	A	B-C	B	C
Duffie et al. (2007)	B-D	B-E	B	A-E	C	A	D-E	B-C-D	D
Chen et al. (2008)	B	A-D	D	A	F	D	C-E	A	D
Lin et al. (2011)	A-F	B	B-E	E	F	A	A	B-C	D
Houweling e Vorst (2005)	A	A-E	A-D	A	B	C	A	A-B	A

(Continua)

Artigo	Tema	Método	Dados	Origem	Variável	Hipóteses	Implicações	JEL	Período
Gordy e Howells (2006)	B-C	C	C-D	A-B	B	D	D	A-D	A
Tian et al. (2012)	A-D	D	A	E	A	A	A	C	E
Grunert e Weber (2009)	A-C	D	B-C-E	A-B-C-E	C-F	A	A-B	A-B	D
Bangia et al. (2002)	B	A	F	E	F	A	B-D	D	E
He e Xiong (2012)	B	B-E	B	B	F	D	B	B	D
Nickell et al. (2000)	B-D	A	B-C	E	B-F	D	A	E	E
Eom et al. (2003)	C	C	C	E	F	A	B-D	B-C-D	D
Schaefer e Strebulaev (2008)	B	C	B-C	A	B	A	D	A	D
Duffie e Lando (2001)	D-E	B-C	C	A	B	A	C	A	C
Veronesi e Zingales (2010)	E	C	C	E	F	A	B-C	E	E
Norden e Weber (2009)	E	B	B-C	A-B-C	B	D	B	A-D	B
Guiso et al. (2013)	F	E	B	A	F	A	E	C-D	A
Ericsson et al. (2009)	E	B	D	A	F	A	A	A	B
Collin-Dufresne et al. (2001)	E	B-D	B-C	A	F	A	A	A	C
Bao et al. (2011)	F	B-C	C	A	F	A	E	E	B
Goss e Roberts (2011)	A	B-C	A	A	F	C	A	B-C-D	D
Jarrow e Turnbull (2000)	A	A	F	E	F	A	E	B-C	E
Bhamra et al. (2009)	B	A-B-C	B-E	A	B-C	C	A	A-C-D	D
Hull et al. (2004)	C	A-B-C	C-D	A-B-C-E	F	B	B	A	B
Almeida e Philippon (2007)	C	A-B	C	E	B	A	A-B	C	E
Grunert et al. (2005)	B-C	C-D	A	B	C	A	C	B	B
Demiroglu e James (2010)	A-F	B	F	A	F	C	B	B-C	C
Zhou (2001)	F	A	F	E	B-C-D	A	A	A-C	E
Brown e Dinc (2009)	A	B-C	A	E	C	D	B-C	B-D	C
Dooley e Hutchison (2009)	D	B	D	A	F	A	E	D	A

Tabela 2.6: Classificação dos artigos de acordo com os códigos apresentados na Tabela 2.1 em cada uma das nove categorias analisadas nesta pesquisa.

Artigo	Principal Objetivo	Conclusão Central	Maior Contribuição
Crouhy et al. (2000)	Compara os modelos <i>KMV</i> e <i>Credit-Portfolio View</i> .	Os modelos têm abordagens distintas porém não é possível afirmar qual é melhor. Os modelos são similares na gestão de carteiras de empréstimos se o efeito de volatilidade no <i>Creditrisk+</i> for baixo. Ainda, o <i>Creditrisk+</i> é mais sensível a qualidade de crédito, demonstrando uma avaliação mais ampla desse fator de risco.	Detalha matematicamente o processo de funcionamento das técnicas analisadas.
Gordy (2000)	Compara os modelos <i>Creditrisk+</i> e <i>Riskmetrics</i> .	Alguns modelos não são capazes de observar o risco associado a derivativos, enquanto modelos na forma reduzida são sensíveis ao risco de crédito e de mercado, sendo apropriados para pricing e gestão de riscos.	Realiza um estudo abrangente dos dois modelos, de modo que todo o contexto teórico é apresentado.
Jarrow e Turnbull (2000)	Testar variáveis macroeconômicas para inserir em um modelo na forma reduzida.	Não há forte relação entre a classificação de risco atribuída pelas agências de <i>rating</i> e a <i>PD</i> .	O estudo sugere a que inclusão de variáveis econômicas pode melhorar as previsões de modelos reduzidos de <i>spreads</i> de créditos.
Nickell et al. (2000)	Avalia evolução da matriz de transição de <i>rating</i> para títulos de longo prazo.	Encontraram a relação de 25% das oscilações nos <i>spreads</i> de crédito associadas a <i>PD</i> e taxa de recuperação.	A <i>PD</i> está associada ao estágio do ciclo de negócio.
Collin-Dufresne et al. (2001)	Os autores buscam entender o que impacta nos <i>spreads</i> de crédito explicados por <i>contingent-claims</i> e <i>no-arbitrage standpoints</i> .	Considerando a falta de transparência, o modelo permite apurar quedas nos prêmios quando há iminência do <i>default</i> .	Alterações nos <i>spreads</i> de crédito em bonds são inexplicáveis considerando apenas medidas de dados financeiros das empresas ou informações de mercado de títulos.
Duffie e Lando (2001)	Aplica modelo na forma reduzida para computar a estrutura a termo em bonds de empresas em casos de assimetria informacional.	Fatores de risco em todo o mercado e os riscos de contraparte específicos das empresas interagem para gerar uma variedade de formas para a estrutura a termo dos <i>spreads</i> de crédito.	O modelo é avaliado passo a passo em sua construção, permitindo uma visão panorâmica da metodologia.
Jarrow e Yu (2001)	Promove uma generalização dos modelos na forma reduzida existentes para incluir intensidades de <i>default</i> dependentes do incumprimento de uma contraparte.	O modelo estrutural aplicado no estudo é flexível a <i>spreads</i> de crédito e pode apontar padrões nas variáveis de risco de crédito.	Apresenta uma nova perspectiva de modelo na forma reduzida.
Zhou (2001)	Desenvolve um modelo na forma reduzida abordando aspectos de difusão presentes em modelos estruturais.		Consegue avaliar o risco atrelado a dívida e a derivativos de crédito por meio de risco de <i>default</i> e <i>interest rate risk</i> .

(Continua.)

Artigo	Principal Objetivo	Conclusão Central	Maior Contribuição
Bangia et al. (2002)	Conduz uma análise do interdependência do <i>rating</i> de firmas americanas a variáveis macroeconómicas e seus ciclos de negócios.	A probabilidade de mudança de <i>rating</i> é significativamente suportada pelo ciclo de negócios.	Trabalha com ciclo de negócios na avaliação de <i>ratings</i> e comprova por meio de testes de <i>stress</i> .
Griffin e Lemmon (2002)	Analisa a relação entre a taxa <i>book-to-market</i> , risco de insolvência e preço das ações.	A média dos retornos das empresas com alta possibilidade de insolvência é baixa, o que é influenciado pela queda no preço das ações e na taxa.	Estes resultados confirmam as evidências de que as empresas com grandes assimetrias de informação são mais propensas a apresentar inconsistências no preço das ações.
Gross (2002)	Estuda clientes de cartão de crédito para verificar <i>PD</i> por meio da <i>duration</i> .	A relação entre <i>default</i> e fundamentos económicos parece ter sofrido alterações no período analisado.	Aplica <i>duration</i> no estudo de consumidores de cartão de crédito e avalia a estabilidade do risco de crédito nestes casos.
Jappelli e Pagano (2002)	Realiza uma pesquisa com dados primários para estudar aspectos do mercado de crédito com relação ao compartilhamento de informações entre as instituições financeiras.	Compartilhamento de informação e volume de empréstimos seguem a mesma tendência.	Constatarem evidências em diferentes países de que bancos compartilham informações para mitigar o risco de crédito.
Eom et al. (2003)	Compara o desempenho empírico de 5 modelos na precificação de títulos.	Os modelos apresentaram alta variação de erro de previsão e forneceram diferenças substanciais na direção e intensidade.	Demonstra teoricamente o contexto matemático e estatístico que envolve cada um dos modelos.
Morellec (2003)	Avalia o impacto do comportamento oportunista do gestor nos preços dos ativos, decisões de endividamento e valor da firma.	Quando o número de opções de crescimento em um conjunto de investimentos da empresa aumenta, o custo de sobreinvestimento diminui, levando o endividamento pra baixo.	Confirma a ideia de que mudanças na economia afetam o endividamento.
Poon (2003)	Utiliza diversas ferramentas matemáticas para mostrar a correlação de retorno no mercado de ações.	É possível medir a correlação de retorno no mercado de ações por outras variáveis.	Um novo modelo multivariado que avalia estrutura de dependência entre mercados.
Amato e Furfine (2004)	Argumenta sobre a relação entre o <i>rating</i> de crédito e o ciclo dos negócios, adotando um modelo <i>probit</i> com variáveis financeiras e macroeconómicas para determinar o <i>rating</i> de crédito.	O <i>rating</i> de risco de crédito de uma firma oscila em consonância com o ciclo do negócio, e isto é causado por mudanças cíclicas dos negócios e também pelos riscos financeiros.	Detectaram pró-ciclicidade em <i>ratings</i> quando observaram empresas de grau de investimento e avaliações de mudanças, o que indica uma possível sensibilidade ao ciclo dos negócios.

Artigo	Principal Objetivo	Conclusão Central	Maior Contribuição
Hillegeist et al. (2004)	Realiza uma análise dos aspectos positivos e negativos dos modelos tradicionais de previsão de falências (<i>Z-score</i> e <i>O-score</i>) e também o modelo de Merton.	O modelo de Merton tem melhor desempenho que os outros para prever falências.	Comparou os modelos de previsão mais empregados no mercado.
Hull et al. (2004)	Avalia a sensibilidade dos <i>spreads</i> de crédito ao bond yields, como também aos anúncios das agências de <i>rating</i> .	Os autores confirmaram a relação negativa entre os <i>spreads</i> de crédito e o <i>rating</i> de crédito.	Aplicam um modelo teórico que interliga os <i>spreads</i> de crédito e os <i>spreads</i> dos juros de títulos.
Jiménez e Saurina (2004)	Verifica o impacto de algumas características de empréstimos (como garantias, tipo de instituição credora e relação entre credor-tomador) no risco de crédito.	As garantias aumentam a probabilidade de incumprimento de um empréstimo. Além disso, verificaram diferenças significativas entre o risco de crédito assumido por vários credores. Empréstimos dos bancos de investimentos são mais arriscados do que em bancos comerciais. Quanto melhor qualificado for o auditor, menor será o retorno para o detentor de bonds da empresa, e este fato é mais evidente em firmas de baixa classificação de crédito.	Um modelo de risco de crédito com dados europeus que considera características pouco adotadas nessa área e mesmo assim apura resultados satisfatórios.
Mansi et al. (2004)	Discute a relação entre características de auditores e financiamento da dívida.	No período pesquisado, o índice de concentração do setor bancário foi alto, gerando menor competitividade e aumento nas margens de juros.	Aponta aspectos relevantes da influência do auditor e custo do capital de terceiros.
Maudos e Guevara (2004)	Propõe um modelo empírico para calcular margem de juros e seus determinantes em bancos europeus na década de 1990.	As pequenas empresas têm retornos mais elevados do que as grandes empresas, se assumirem alto risco de inadimplência. Ainda, as ações geram retornos mais elevados ao invés de aumentar de valor.	A modelagem abordada permite determinar a margem de juros envolvendo a competitividade e custos operacionais.
Vassalou e Xing (2004)	Estuda a relação entre risco de inadimplência e retorno das ações tendo como medidor o modelo de Merton.	É possível obter tal solução por meio de uma gestão de risco usando opções europeias.	O próprio autor relata que este é o primeiro estudo que utiliza modelo de Merton para medir risco de crédito para empresas individuais e avaliar o seu efeito sobre os retornos das ações.
Bielecki et al. (2005)	Encontrar uma solução ótima para a seleção de ativos em uma carteira de investimentos/ativos.	A <i>PD</i> possui o melhor previsto quando se incorpora fatores não-financeiros no modelo.	Um novo modelo de otimização que considera a aversão a eventos de falência.
Grunert et al. (2005)	Investiga a participação de fatores não-financeiros em <i>ratings</i> de crédito inter-nos.		A inserção de medidas não-financeiras na avaliação de risco de crédito.

Artigo	Principal Objetivo	Conclusão Central	Maior Contribuição
Houweling e Vorst (2005)	Aplica modelos de forma reduzida para precificar prêmios de CDS.	Os modelos de forma reduzida além de mais objetivos possuem maior precisão na precificação de CDS.	O estudo é baseado em mais de 10 mil bonds, incluindo bonds soberanos.
Yu (2005)	Examina a relação entre a estrutura a termo dos <i>spreads</i> de crédito e da qualidade da informação contábil.	A qualidade da informação contábil pode trazer aumento de custos financeiros.	Comprova empiricamente o efeito estrutura a termo, ou seja, as empresas que divulgam informações mais precisas têm menores <i>spreads</i> de crédito no curto prazo.
Allen e Carletti (2006)	Pretende mostrar que efeito da transição de risco de crédito realizado por bancos e seguradoras.	O resultado pode ser uma diversificação positiva. Caso contrario pode ocasionar um contágio decorrente do risco de crédito.	Faz uma avaliação detalhada de processos de inovação financeira que levam a resultados positivos ou a contágio de risco.
Gordy e Howells (2006)	Busca informações sobre a proclividade que envolve a disciplina de mercado.	A extensão da ciclicidade dos requisitos de capital depende fortemente de como novos empréstimos se comportam na economia.	Foi realizada uma análise minuciosa do capital econômico apurado nos modelos internos.
Gropp et al. (2006)	Examina a dificuldade financeira em bancos por meio de determinantes do risco de crédito.	Distância do <i>default</i> tem baixo poder explicativo e os <i>spreads</i> são bons indicadores para bancos observarem sua fragilidade.	Trabalha com <i>spreads</i> de derivativos conjuntamente com preço de ativos para tratar de disciplina de mercado.
Hackbarth et al. (2006)	Estuda a sensibilidade do risco de crédito a mudanças macroeconômicas e estrutura de capital.	Confirma a hipótese de risco de crédito sofrer influências de alterações macroeconômicas como também na escolha da estrutura de capital, o que é evidenciado pela alta taxa de <i>default</i> em períodos de crise.	O trabalho constrói um arcabouço teórico consistente que permite uma gestão sofisticada do risco de crédito em termos de alavancagem e perspectivas do mercado.
Rosenberg e Schuermann (2006)	Implementa uma metodologia aplicando cópulas na mensuração dos riscos operacional, de mercado e de crédito.	Os riscos podem ser calculados de forma separada e ajustados com cópulas.	A implementação de cópulas na gestão de riscos.
Zhu (2006)	Discute o impacto do desenvolvimento do mercad de derivativos de crédito na precificação do risco de crédito.	Os resultados indicam que CDS são mais propensos a fornecer um indicador preciso do preço do risco de crédito do que os <i>spreads</i> das obrigações financeiras.	Compara <i>spreads</i> de bonds e de cds, com o intuito de verificar a sensibilidade do risco de crédito associado ao mercado de derivativos.
Acharya et al. (2007)	Avalia como a dificuldade do setor influencia nas recuperações dos credores de uma empresa proximas do <i>default</i> .	A situação econômica do setor exerce papel importante e também é um fator impactante na taxa de recuperação do credor no momento do <i>default</i> .	Argumenta sobre as implicações dos modelos de avaliação nos títulos corporativos.

Artigo	Principal Objetivo	Conclusão Central	Maior Contribuição
Almeida e Philippon (2007)	Examina o impacto dos preços de títulos corporativos no risco de crédito das firmas.	Os custos marginais ajustados ao risco de dificuldades financeiras e os benefícios fiscais marginais da dívida possuem volumes semelhantes.	A estrutura de capital pode ser influenciada por custos de insolvência.
Altman e Sabato (2007)	Apresenta o desempenho de um modelo para medir PD para pequenas e médias empresas italianas.	O modelo é mais preciso que modelos anteriores com a mesma proposta.	Utiliza uma regressão logística para medir PD em PME's usando somente variáveis financeiras.
Battiston et al. (2007)	Por meio de uma modelagem matemática, identifica-se de um conjunto mínimo de mecanismos que reproduzem qualitativamente a empresa e o padrões para a produção, o crescimento e as falências.	Obtem-se um modelo teórico que considera a interação local o que provoca um efeito serial de falências.	A análise da correlação espaço-temporal, em termos de crescimento e falências.
Carling et al. (2007)	Propõem um modelo baseado na duração para explicar o tempo de sobrevivência até o <i>default</i> dos mutuários na carteira de crédito.	Variáveis macroeconômicas têm poder explicativo significativo para o risco de inadimplência, além de uma série de índices financeiros comuns.	Considera efeitos macro no modelo, além de ser capaz de explicar o nível absoluto de risco.
Chatterjee et al. (2007)	Faz uma análise profunda a respeito do risco de crédito associado a households em consonância com a legislação americana de falências.	Demonstra a existência de equilíbrio entre os preço e <i>defaults</i> que ocorrem em households de mesma característica.	A modelagem aplicada permitiu observar a sensibilidade ligada a fatores macroeconômicos.
Das (2007)	Comprovar a eficiência de um modelo formulado em um processo estocástico de Poisson para verificar a intensidade de <i>defaults</i> ao longo do tempo e completa a pesquisa realizando uma análise de correlação de <i>default</i> com variáveis macroeconômicas por cópulas.	Com base nesta técnica, os testes de hipótese conjunta revela que intensidades de <i>default</i> são medidas corretamente e possuem propriedade duplamente estocástica.	Introduz um modelo de risco de crédito influenciado por intensidade de <i>defaults</i> usando um processo de poisson como molde.
Duffie et al. (2007)	Propõe um modelo de risco de crédito multi-período que aplica covariâncias macroeconômicas e dinâmicas da firma.	Em alguns setores, a estrutura a termo das taxas de risco de <i>default</i> está fortemente associada a situação econômica e na estrutura de capital.	Determina PD por meio da dinâmica das variações.

Artigo	Principal Objetivo	Conclusão Central	Maior Contribuição
Gopalan et al. (2007)	Investiga a forma de participação de grupos corporativos no mercado de capitais.	Grupos corporativos na Índia existem inicialmente para proteger as firmas membro de dificuldades financeiras.	Apresenta os pontos positivos e negativos para empresas de grupos corporativos.
Hennessy e Whited (2007)	Por meio de simulação, os autores aplicam um modelo estrutural baseado em investimentos, caixa, alavancagem e <i>default</i> para estimar custos de financiamento.	As análises confirmam que os resultados simulados se aproximam da realidade, de modo que os custos de financiamento em corporações podem ser explicados pelos custos de falência e outras taxas.	A escolha dos determinantes dos custos de financiamento é muito sutil, pois o contexto é fundamental.
Jorion e Zhang (2007)	Investiga o efeito de contágio no setor originado de eventos de <i>default</i> nos preços dos ativos e derivativos.	Evento de falência impacta nos títulos de empresas do mesmo setor e liquidação influencia no preço das ações das firmas do setor correspondente, devido a competitividade.	Promove uma associação entre efeitos de contágio, características do setor e <i>default</i> .
Agarwal e Taffler (2008)	Comparar dois modelos de risco de crédito, baseados em informações de mercado, com o modelo <i>Z-score</i> de Altman.	O <i>Z-score</i> é mais preciso, porém sem significância estatística. Sua vantagem está no melhor ajuste das receitas ao risco, lucros, retorno do capital investido e retorno sobre o capital ajustado ao risco em comparação a abordagem de avaliação de risco de crédito com base no mercado. Os testes constataram que todos os modelos captam informações a respeito de falência, mas nenhum método substitui o outro.	A análise do risco de crédito por modelos baseados em dados contábeis são mais robustos em relação aos modelos de variáveis de mercado.
Angelini et al. (2008)	Empregar a técnica de rede neural para a estimativa da probabilidade de <i>default</i> .	O modelo foi considerado eficiente em duas formas de aplicação.	Trabalhou com redes neurais utilizando 15 variáveis financeiras na predição de <i>PD</i> para firmas italianas.
Bharath e Shumway (2008)	Analisa o desempenho do modelo de Merton com relação ao fator associado a distância do <i>default</i> .	O modelo não é viável para medir <i>PD</i> , no entanto serve de fonte de informação para prever <i>default</i> .	Modificações no modelo tradicional de Merton pode apresentar melhor poder explicativo.
Brissimis et al. (2008)	Realiza uma análise da relação entre o desempenho dos bancos e a reforma do setor.	Uma maior presença de regulação leva os bancos a melhorarem sua performance.	Estuda empiricamente e praticamente todo o período de reforma para apontar os principais indicadores de performance das instituições financeiras.

Artigo	Principal Objetivo	Conclusão Central	Maior Contribuição
Campbell et al. (2008)	Busca entender os fatores que estão ligados a eventos de falência e aos preços das ações de empresas de altos valores de <i>PD</i> . Discute como a informação pode estar no preço da ação e a sua influência em retornos futuros.	Ativos com <i>PD</i> alta tem propensão a apresentar baixos retornos em média.	Apresenta um modelo na forma reduzida que apresenta baixa erro estatisticamente significativo.
Chen et al. (2008)	Avalia empiricamente a natureza de ajustes em contratos de empréstimos e a medida em que eles mitigam o efeito do código de falência sobre os resultados do <i>default</i> .	Os <i>spreads</i> de títulos Baa-Aaa são explicados a partir de uma perspectiva puramente de crédito.	Identificaram possíveis maneiras de se determinar o <i>spreads</i> .
Davydenko e Franks (2008)	Avalia os efeitos de contágio provenientes de eventos de falência em termos de setor e participação dos colaboradores.	Os bancos ajustam consideravelmente suas práticas de financiamento e de reorganização em resposta ao código de falência do país.	Os autores destacam que não encontram publicação alguma que estuda <i>default</i> em diferentes países em que se tenha a possibilidade de comparar os dados.
Hertzel et al. (2008)	Baseado em um modelo estrutural, pretende prever a proporção de hedge em bonds vinculada estritamente ao risco de crédito da firma.	Ocorrem retornos anormais negativos em empresas fornecedoras e há sinais de contágio intersetorial quando o mercado recebe indícios de <i>default</i> ou pedidos de falência.	O evento de falência atinge não somente as empresas do setor, mas também os colaboradores.
Schaefer e Strebulaev (2008)	Baseado em um modelo estrutural, pretende prever a proporção de hedge em bonds vinculada estritamente ao risco de crédito da firma.	Os retornos sobre o patrimônio líquido da empresa e títulos sem risco explicam aproximadamente metade dos rendimentos dos títulos com mesmo grau de investimento e abaixo, e mais de um terço para os títulos de alto rendimento.	Faz uma análise crítica de performance dos modelos empregados.
Beber et al. (2007)	Busca entender a forma com que investidores aplicam seus recursos e de que maneira avaliam títulos corporativos.	Investidores avaliam a possibilidade de inadimplência e a liquidez dos títulos nos quais pretendem obter retorno.	Descobre que o mercado de títulos europeu tem comportamento ao americano com relação a preocupação dos investidores no quesito qualidade de crédito e liquidez.

Artigo	Principal Objetivo	Conclusão Central	Maior Contribuição
Bonfim (2009)	Avalia simultaneamente os efeitos de algumas das dimensões do risco de crédito corporativo, considerando informações contáveis da firma, bem como os dados macroeconômicos e financeiros, tentando entender como os fatores de risco idiossincrático e sistemático determinam o <i>default</i> . Busca informações sobre as mudanças nos mercados emergentes e o comportamento dos <i>spreads</i> de crédito quando ocorrem eventos de <i>default</i> nos Estados Unidos.	Os resultados obtidos permitem concluir que a dinâmica macroeconômica têm uma importante contribuição adicional (e independente) para explicar o que leva as empresas a <i>default</i> . Os eventos americanos impactam significativamente nos mercados emergentes.	Confirmam que a economia também é um fator determinante do <i>default</i> . Neste caso, notaram a assunção de risco excessiva das empresas em momentos de economia em expansão.
Dooley e Hutchison (2009)	Examina a distribuição de probabilidade condicional para perdas em carteiras de crédito.	Desconsiderar aspectos não observáveis pode provocar estimativas tendenciosas do <i>VaR</i> para carteiras de crédito de maior volume.	A análise baseou-se no <i>VaR</i> para verificar o elo entre os mercados estudados.
Ericsson et al. (2009)	Observa a sensibilidade dos derivativos de uma empresa na deformação da estrutura de capital, volatilidade e taxa de juros livre de risco.	Confirmou o efeito teoricamente suposto e com validação estatística.	A metodologia empregada é mais eficiente na mensuração das perdas em carteiras de títulos corporativos e pode ser aplicada em outros tipos de análises.
Grunert e Weber (2009)	Testa quatro hipóteses sobre qualidade creditícia de mutuários e a taxa de recuperação.	O autor confirmou as quatro hipóteses testadas.	Aplicação de variáveis do risco de <i>default</i> para estudar <i>CDS spreads</i> .
Huang et al. (2009)	Realiza modelagem e teste de stress para medir risco sistemático em instituições financeiras usando dados financeiros e <i>CDS spreads</i> .	O risco sistemático é maior quando a média de <i>PD</i> aumenta ou quando a exposição a fatores comuns aumenta.	Calcula a taxa de recuperação usando variáveis macroeconômicas.
Ivashina (2009)	Examina como a participação acionária de banco líder de mercado está ligada a assimetria de informação; ainda, mede o impacto da ação no <i>spread</i> bancário cobrado para os tomadores.	Bancos com carteira maiores e mais diversificadas têm uma vantagem competitiva, porque eles podem oferecer menores custos de financiamento para o mutuário.	O modelo traz avanços na mensuração do risco sistemático ao acoplar uma <i>proxy</i> do risco de crédito. Inclui efeitos do domínio de mercado e indicadores na análise.

(Continua.)

Artigo	Principal Objetivo	Conclusão Central	Maior Contribuição
Jorion e Zhang (2009)	Desenvolve um modelo de risco de crédito que capta a interferência causada por relações com contrapartes falidas.	Os preços das ações reagem negativamente e ocorre um aumento no <i>spread</i> do cds quando a empresa possui relação direta com devedores falidos.	De acordo com os autores, este é o primeiro paper que utiliza uma ligação direta e clara entre a firma e a contraparte para medir risco.
Norden e Weber (2009)	Pretende explicar o comportamento do preço das ações por meio de comovimento associado a CDS e bonds.	Os preços das ações reagem em sentido oposto às mudanças nos preços de derivativos.	Estes resultados contribuem para a investigação sobre a eficiência do mercado envolvendo derivativos de crédito.
Bhamra et al. (2009)	Desenvolve uma análise teórica sobre os custos de capital de terceiro e capital próprio no intuito de verificar o impacto de variáveis macroeconômicas no prêmio pelo risco e no <i>spread</i> de crédito.	O modelo teórico é capaz de determinar <i>PD</i> e <i>spread</i> de crédito e, simultaneamente, calcular <i>equity premium</i> e preço de ações.	Propõe uma junção entre <i>asset pricing</i> e finanças corporativas.
Brown e Dinc (2009)	Avalia o fenômeno <i>too-big-too-fail</i> em bancos de mercados emergentes.	Em setores frágeis os bancos em dificuldades tendem a serem protegidos por uma tolerância regulatória.	O papel do órgão regulador bancário em países de mercado emergente.
Chava e Purnanandam (2010)	Verifica o impacto de risco de inadimplência no preço das ações.	Encontraram uma forte relação entre o retorno esperado e o risco de inadimplência.	Utilizam dados ex ante por meio do custo de capital implícito como proxy para estimar os retornos das ações.
Chen (2010)	Desenvolve um modelo estrutural que inclui variáveis macroeconômicas.	O modelo atinge seu objetivo além de ser apreendido de forma consistente.	A modelagem está focada nos efeitos da prêmio de risco sobre as decisões de financiamento das empresas e os preços dos títulos corporativos.
Demiroglu e James (2010)	Pesquisa quais são os características comuns presentes nos financiamento de LBOs em negócios que envolvem grupos de private equity.	A participação de grupos de private equity em LBOs influencia negativamente nos <i>spreads</i> de crédito e nos financiamentos.	Relaciona grupos de private equity e custos com <i>LBOs</i> .
Errais et al. (2010)	Apresenta uma metodologia pouco encontrada na literatura, <i>affine point process</i> , por uma abordagem <i>top-down</i> aplicada em valoração de derivativos.	A técnica de <i>self-extracting</i> para avaliação de carteiras de crédito pode ser aplicada para <i>bonds</i> e empréstimos.	Por meio de ferramental matemático, demonstra o funcionamento do <i>affine point process</i> na análise de risco de crédito.

Artigo	Principal Objetivo	Conclusão Central	Maior Contribuição
Foos et al. (2010)	Examina a relação entre o crescimento das perdas com empréstimos no desempenho de bancos.	O aumento anormal do volume de empréstimos causa mais perdas a instituição.	Crescimento súbito em determinada atividade pode causar resultados indesejáveis.
George e Hwang (2010)	Retoma a discussão sobre a relação negativa entre retorno e alavancagem.	Observa que baixo retorno dos ativos está diretamente relacionado ao risco sistemático, que também é alimentado pelo custo de insolvência. Por outro lado, as empresas com altos custos preferem menor alavancagem e assim gera uma menor <i>PD</i> .	<i>Book-to-market</i> não é uma medida de risco de dificuldades financeiras, mas sim captura exposição ao risco de preço que não está relacionado com a estrutura de capital.
Güntay e Hackbarth (2010)	O objetivo deste trabalho é analisar se as variações na previsão provocam alterações nos mercados de bonds de empresas similares ao que ele desempenha nos mercados de ações.	Bonds de empresas com maior dispersão de previsão têm <i>spreads</i> de crédito significativamente mais elevados e retornos futuros mais elevados do que os bonds similares.	Diferenças institucionais entre mercados de ações e títulos merecem maior atenção.
Tang e Yan (2010)	Estuda a correlação entre o risco de mercado e o risco de crédito para derivativos.	Oscilações macroeconômicas, taxas de crescimento, volatilidade do crescimento, sentimento do investidor e risco de jump contribuem para o bom desempenho do modelo.	A modelagem de risco que inclui medidas de crescimento e taxas de crescimento na análise de derivativos de crédito.
Veronesi e Zingales (2010)	Avalia o efeito do Plano de Paulson revisado no mercado.	O plano atingiu seu objetivo e conseguiu realocar uma eficiente redistribuição de recursos.	A avaliação do desempenho financeiro de bancos antes e depois do plano por meio de derivativos de crédito.
Acharya et al. (2011)	Investiga a ligação entre os direitos dos credores e da política de investimento das empresas.	As empresas tendem a reduzir seus riscos em países onde os credores são fortemente protegidos por lei.	Levanta a discussão sobre os direitos dos credores e os benefícios das corporações em ambientes de maior proteção.
Bao et al. (2011)	Discute a relação entre asset-pricing e liquidez de títulos.	Baixa liquidez de títulos está fortemente ligada a baixa dos preços dos ativos e está associada a fatores como maturidade, <i>rating</i> e montante.	A liquidez pode ser explicada por oscilações negativas nos preços dos ativos.
Goss e Roberts (2011)	Estuda o passivo dos bancos e sua relação com fatores socio ambientais.	Os bancos podem aplicar corporate social responsibility com discernimento, porém há situações de conflitos de interesse.	Incluíram medidas de sustentabilidade na avaliação dos <i>spreads</i> de crédito.

Artigo	Principal Objetivo	Conclusão Central	Maior Contribuição
Lin et al. (2011)	Examina o impacto dos direitos de controle no valor da empresa.	Com dados da Europa e Ásia, constataram que inconsistências entre fluxo de caixa e direitos de controle leva a firma a um maior custo de financiamento da dívida.	A percepção da influência de direitos de controle no custo de capital.
Battiston et al. (2012)	Apresenta um modelo de rede fundamentado na relação tomador-creditor feito por instituições financeiras, considerando a interrelação entre os dados contábeis.	Diversificação do risco individual pode ter efeito ambíguo em nível sistêmico.	Os efeitos da diversificação do risco sobre o risco sistêmico, através do desenvolvimento de um novo modelo de “ <i>default</i> em cascata” ilustrado por uma rede financeira.
Griffin e Tang (2012)	Propõe uma análise empírica e crítica as classificações de crédito aplicadas a <i>CDOs</i> .	A correlação entre o modelo aplicado e a classificação real para o grupo melhor classificado é baixa, o que indica a necessidade de ajustes. Adequações advindas de fatores adicionais não possuem poder informacional.	Usando modelos teóricos de classificação de crédito recentes, faz uma aplicação em dados reais e discute as normas definidas pelos modelos e praticadas no mercado.
He e Xiong (2012)	Argumenta a implantação de um modelo que verifica a interação entre liquidez da dívida e o risco de crédito.	A queda na liquidez de mercado da dívida induz a um aumento dos prêmios de liquidez de <i>default</i> .	Demonstra matematicamente um modelo que satisfaz seu objetivo considerando a possibilidade de rolagem da dívida.
Tian et al. (2012)	Faz uma revisão sobre um dos métodos de classificação baseados em previsão de máquina, apresentando suas diversas formas e aplicações.	As máquinas de vetor de suporte conseguem bons resultados no ramo econômico-financeiro.	Esclarece pontos importantes sobre a ferramenta.
Guiso et al. (2013)	Investiga o impacto do custo de <i>default</i> para as pessoas em seus patrimônios.	Tal custo cresce com a riqueza e está atrelado a fatores financeiros, como também sentimentais. Ainda, existe uma possibilidade de contágio.	Poucos trabalhos discutem <i>default</i> estratégico.
Jiménez et al. (2014)	Aplica um modelo de dois estágios para determinar a qualidade de crédito das empresas e seus impactos nas instituições financeiras.	Baixa taxa de juros overnight provoca um aumento de risco aos bancos, refletido pela maior concessão de empréstimos e bancos menos capitalizados arriscam ainda mais, evidenciado por maior volume de concessões não garantidas.	Aponta os aspectos de tomada de risco ligados a política monetária.

Tabela 2.7: Descrição sucinta dos principais objetivos, conclusões e contribuições de cada artigo discutido neste estudo.

Procurando proporcionar uma visão ampla de todas as classificações, as Figuras 2.4 a 2.11 mostram os resultados, da classificação dos 83 artigos revisados em cada um dos quesitos analisados.




Figura 2.4: Resultado da classificação para a categoria 1 “Tema Principal”.

De maneira geral, os estudos observados neste trabalho não apresentaram grande concentração em um único assunto, porém há uma forte tendência na área de gestão de riscos, modelos de risco de crédito e aplicações de análises estatísticas em derivativos de crédito. Alguns trabalhos tiveram mais de um tipo de classificação, devido a apresentação de outros temas com a mesma intensidade ou ligação entre eles. Além disso, foram identificados pouquíssimos trabalhos nas subcategorias A-B, A-C, B-E, B-F, C-E, D-F e A-C-D-E. Por exemplo, [Jiménez e Saurina \(2004\)](#) ressaltam que a literatura tem usado boa parte dos dados gerados no mercado americano. No entanto, [Gropp et al. \(2006\)](#) afirmam que existe certa dificuldade em trabalhar com alguns indicadores do mercado de ações. Uma provável explicação para essa ocorrência é a falta de habilidade dos gestores de risco e pesquisadores fora do território dos EUA em lidar com escassez de dados e entender a relação entre medidas macroeconômicas e informações do mercado. Consequentemente, esse fato constitui o Gap_1 que deveria ser abordado em pesquisas futuras e pode ser apresentado da seguinte maneira:

Gap_1 : Estudos observados que dão continuidade aos trabalhos de [Jiménez e Saurina \(2004\)](#) e [Gropp et al. \(2006\)](#) deveriam ser explorados, pois é possível analisar o risco da contraparte, como faz [Jarrow e Yu \(2001\)](#) ou mesmo transferir o risco via derivativos, fornecendo alternativa de dados para o desenvolvimento da pesquisa.




Figura 2.5: Resultado da classificação para a categoria 2 “Método Aplicado”.

No que diz respeito ao segundo critério de classificação, o destaque fica para a econometria fortemente aplicada por meio séries temporais, representando 38% dos métodos utilizados nos artigos. Apesar disso, o caráter mais abstrato dos trabalhos teóricos não impediu o seu bom desempenho como pesquisas de maior impacto, demonstrando a necessidade desse tipo de literatura. Consequentemente, percebe-se que trabalhos com métodos computacionais e/ou simulações são poucos citados e utilizados em risco de crédito o que, por sua vez, é identificado como *Gap*₂.

Um novo estudo sobre CDS e as avaliações de crédito têm mostrado que é possível fazer análise interessante. Por exemplo, [Wengner et al. \(2015\)](#) estudou CDS com o intuito de encontrar qualquer relação entre as classificações de crédito e as reações do mercado para diferentes indústrias. Como resultado, foram confirmadas as suas hipóteses. Enquanto isso, recentemente [Gallegati e Ramsey \(2014\)](#) discutiram o poder dos *spreads* de crédito para prever o crescimento em termos de investimento considerando uma análise mais econômica.

Em relação ao método usado, é interessante salientar que a econometria tem sido frequentemente aplicada por séries de tempo, representando 38% dos métodos utilizados nos artigos. No entanto, a natureza abstrata de estudos teóricos não afetou a importância do seu impacto, demonstrando a necessidade para este tipo de literatura. Por exemplo, [Casalin e Dia \(2014\)](#) teriam uma teoria promissora, apresentando um modelo que incluiu os custos de ajustamento quando se estuda investimento. Por outro lado, nota-se que os métodos e ou simulações computacionais são raramente usados em estudos

sobre risco de crédito ou até mesmo citado, de modo que vale a pena identificar a seguinte lacuna na literatura:

Gap₂ : Além dos trabalhos de [Chatterjee et al. \(2007\)](#), [Battiston et al. \(2007\)](#), [Allen e Carletti \(2006\)](#), [Tian et al. \(2012\)](#), [Collin-Dufresne et al. \(2001\)](#) e [Grunert e Weber \(2009\)](#), há uma carência de estudos na área de risco de crédito que abordem intensivamente a utilização de métodos computacionais e ou simulações. Há indícios de crescimento de trabalhos com esta propriedade, mas ainda não se sobressaíram como referenciais de pesquisa. Talvez a característica abstrata e de metodologia inovadora causem receio, além da tendência ao empirismo da economia e das finanças.




Figura 2.6: Resultado da classificação para a categoria 3 “Origem dos Dados”.

Com relação a classificação denominada “Origem dos Dados” em que se aplicam as pesquisas, nota-se que os estudos estão pulverizados, com exceção das pesquisas com empresas que domina essa classificação. Provavelmente, isto se deve ao fato da disponibilidade de dados e da dificuldade de se analisar dados provenientes de instituições financeiras. Por outro lado, as variáveis macroeconômicas são bastante citadas em modelos de risco de crédito, mas ainda é pouco aplicada em outros temas, mesmo com o aumento da transparência nas contas das instituições governamentais. Conseqüentemente, esse fato caracteriza o *Gap₃*, a saber:

Gap₃ : Complementar os trabalhos de [Chen \(2010\)](#) e [Bonfim \(2009\)](#) que observam as variáveis macroeconômicas quando estão considerando risco de crédito, principalmente em países que já apresentam ou disponibilizam as informações de suas contas;




Figura 2.7: Resultado da classificação para a categoria 4 “Local de Origem dos Dados”.

A classificação “Local de Origens dos Dados” mostra uma alta concentração de pesquisa nos Estados Unidos, alguns resultados na Europa e outras localidades são praticamente inexploradas. Embora os mercados emergentes possam contribuir mais nos próximos anos para o entendimento sobre risco de crédito, até porque são uma grande fonte de risco de crédito em qualquer situação, foi identificado que as pesquisas como, por exemplo, [Gopalan et al. \(2007\)](#) que observam esses países são escassas. Nesse sentido, o Gap_4 pode ser compreendido da seguinte maneira:

Gap_4 : Estudos já realizados nos Estados Unidos e na Europa podem ser replicados em países emergentes como, por exemplo, os que compõem os BRICS e também na Ásia, para determinar se os resultados e conclusões alcançadas anteriormente seguem a mesma tendência ou mesmo se são válidos de maneira generalizada;

É importante salientar que provavelmente a maior captação americana é justificada pela intensidade do mercado nacional, a quantidade de empresas no mercado financeiro e, obviamente, o maior interesse dos pesquisadores americanos em estudar as características presentes em seu país.

No caso das variáveis de interesse, observou-se que os autores trabalharam com diversas medidas e que nem sempre o objetivo tinha um relacionamento próximo com risco de crédito. Entretanto, os estudos desenvolveram análises em que algumas das dimensões tinham participação estratégica. Além disso, as variáveis muitas vezes estavam associadas a modelos de maior complexidade, demandando uma procura criteriosa e, algumas vezes,




Figura 2.8: Resultado da classificação para a categoria 5 “Variável de Interesse”.

subjetiva. Uma falta de publicações sobre a exposição ao *default* é nítida em estudos de maior impacto o que, por sua vez, compreende o Gap_5 , descrito a seguir:

Gap_5 : Realização de estudos focados na exposição ao *default* que observem os apontamentos dos *Gaps* previamente apresentados;

Ainda no tocante ao Gap_5 , poucos artigos apresentaram discussão sobre LGD ou taxa de recuperação, outro subitem que merece a atenção dos pesquisadores. É bem provável que a justificativa para essa falta de trabalhos esteja associada a dificuldade de se obter dados. Mesmo nos Estados Unidos, onde a quantidade de dados e base de dados é acentuada, valores empíricos de taxas de recuperação não são amplamente divulgados ou conhecidos por muitos acadêmicos e práticos. Da mesma forma, as perdas esperadas e capital econômico foram assuntos poucos abordados (EVANOFF et al., 2011), mesmo após o acordo da Basileia II incentivar os bancos a desenvolverem seus próprios modelos para cálculo dos requisitos de capital.

Na categoria 6, estudou-se a quantidade de hipóteses definidas nos artigos. Quando essa informação não estava explícita no trabalho, decidiu-se pela contagem de objetivos. Alguns trabalhos descreviam apenas uma intenção de resultados ou mesmo argumentava a trajetória da pesquisa e, dessa forma, classificou-se tais trabalhos na primeira opção. Pode parecer que essa junção tenha inflado a opção A, mas o resultado é perfeitamente aceitável, uma vez que muitos objetivos podem tornar o trabalho extenso




Figura 2.9: Resultado da classificação para a categoria 6 “Quantidade de Hipóteses ou Objetivos”.

ou divergente. Embora tal fato não permita a identificação de um *Gap* de maneira específica, o mesmo indica que muitos pesquisadores não especificam quais suposições estão sendo testadas em seus trabalhos o que, por sua vez, pode gerar um demasiado número de trabalhos muito semelhantes.

A qualidade dos trabalhos é evidenciada no sétimo quesito, no qual verifica-se uma grande quantidade de trabalhos descritos como novas perspectivas, indicando pesquisas inovadoras e de forte impacto. Aplicações de modelos pré-existentes, algumas comparações e, também, confirmações de trabalhos anteriores completam a lista, porém doze artigos não foram classificados em nenhum desses casos, devido a pesquisa não ter afinidade com os critérios sugeridos.

No que concerne à classificação *JEL*, oito artigos não foram classificados por não disponibilizarem a classificação em qualquer uma de suas versões. Desconsiderando esse problema, percebe-se uma certa igualdade na proporção dos trabalhos com relação aos campos de pesquisa atendidas, o que pode indicar a presença de especialistas em diferentes áreas contribuindo em estudos de finanças.

Por fim, a última categoria trata do período de análise aplicado nos artigos. Quase a maioria dos artigos desenvolveram seus estudos com dados acima de dez anos, indicando uma tendência em análise de longo prazo. Uma análise com horizonte mais amplo de tempo ocasiona uma robustez maior nos resultados, pois a estatística inspirará mais confiança em suas inferências e, também, um padrão que deverá ser observado nos




Figura 2.10: Resultado da classificação para a categoria 7 “Implicações”.




Figura 2.11: Resultado da classificação para a categoria 8 “Área de Estudo (*JEL*)”.

trabalhos futuros na área de “Risco de Crédito”.

Além dessa sistematização, procurando identificar direções para os estudos futuros, foi realizado um estudo sobre as referências bibliográficas apresentadas em cada




Figura 2.12: Resultado da classificação para a categoria 9 “Período de Análise”.

artigo, utilizando abordagem baseada em quantidade de citações. Tal processo tem como objetivo identificar padrões de literatura e, principalmente, os trabalhos que conseguem gerar novas vertentes dentro da área de risco de crédito. O resultado desse estudo é apresentado na Figura 2.13.

Observa-se cinquenta e duas ligações, que identificam as citações locais, e vinte e oito trabalhos citados pelos estudos que compõem nosso banco de artigos com média acima de cinco citações anuais, que são apresentados pelos círculos. A Tabela 2.8 mostra os artigos presentes na Figura 2.13, o número de citações locais (NCL) e o total de citações (ou também quantidade de citações globais, QCG) segundo a base de dados *Scopus*.

Nota-se que artigos pós 2009 não estão presentes na Figura 2.13. De fato, os trabalhos ainda são recentes e novos estudos provavelmente optaram por usar como referencial um dos vinte e oito trabalhos mencionados na tabela 2.8. Isto pode indicar que os artigos de maior relevância estejam mais preocupados com a qualidade de suas referências e consideram medidas de desempenho em publicações, como *h-index* e fator de impacto, apenas consequências de uma pesquisa bem elaborada, coerente e consistente.

Muitos trabalhos têm demonstrado nos últimos anos preocupações sobre crises financeiras. [Prabha e Wihlborg \(2014\)](#) é uma sugestão de potencial estudo relevante neste contexto.

Riscos em instituições financeiras foi outro assunto comentado, e junto com períodos de crise foram fortemente analisados, mas tais estudos não foram considerados

No.	#	Artigo	NLC	GQC
1	1	Crouhy et al. (2000)	2	153
2	2	Gordy (2000)	5	151
3	3	Jarrow e Turnbull (2000)	2	56
4	4	Duffie e Lando (2001)	9	201
5	5	Jarrow e Yu (2001)	3	104
6	6	Zhou (2001)	4	104
7	8	Bangia et al. (2002)	3	92
8	11	Griffin e Lemmon (2002)	5	88
9	12	Hillegeist et al. (2004)	6	176
10	13	Vassalou e Xing (2004)	8	259
11	15	Eom et al. (2003)	7	134
12	18	Jiménez e Saurina (2004)	2	45
13	21	Hull et al. (2004)	5	110
14	23	Yu (2005)	2	60
15	26	Houweling e Vorst (2005)	3	53
16	30	Zhu (2006)	4	65
17	32	Hackbarth et al. (2006)	5	69
18	33	Das (2007)	7	98
19	34	Carling et al. (2007)	2	34
20	35	Duffie et al. (2007)	7	135
21	37	Jorion e Zhang (2007)	3	62
22	40	Acharya et al. (2007)	7	82
23	42	Almeida e Philippon (2007)	4	46
24	46	Bharath e Shumway (2008)	6	143
25	50	Campbell et al. (2008)	2	136
26	52	Bonfim (2009)	2	31
27	58	Chen et al. (2008)	2	38
28	60	Duffie et al. (2009)	2	60
Soma			119	2785

Tabela 2.8: Artigos presentes nesta pesquisa com duas ou mais citações (i.e., $NLC \geq 2$) de outros artigos dentro da amostra de artigos incluídos nesta revisão da literatura. A última coluna mostra a quantidade de citações do artigo na literatura como um todo (GQC). **Fonte de dados:** *Web of Science*.

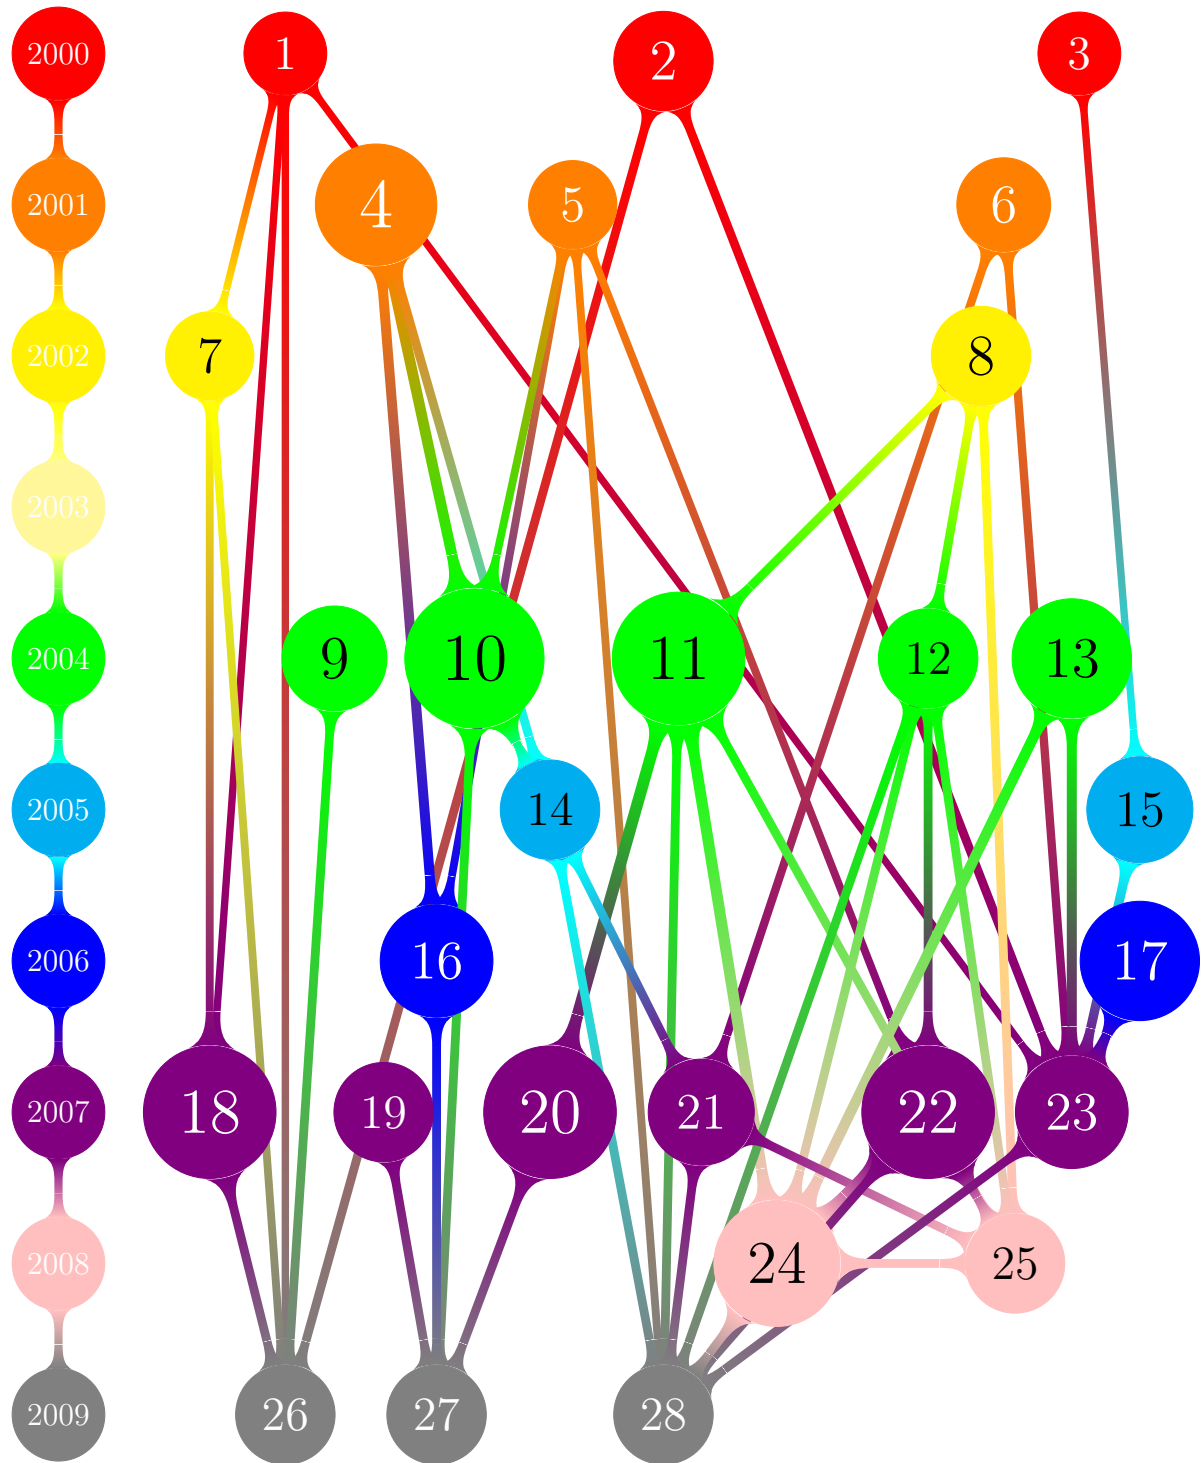


Figura 2.13: Mapa de referências dos 83 artigos analisados nesta seção do trabalho que apresentam pelo menos duas citações de outros artigos que fazem parte deste estudo, denominado citações locais. O tamanho dos círculos (diâmetro) está relacionado à quantidade de citações locais, conforme a Tabela 2.8.

relevantes ainda, por exemplo [Zhang et al. \(2014\)](#). Choques em Economia/Quadro financeiro também foram comentados nos estudos mais recentes. No entanto, não há artigo proeminente neste tópico até agora. Em essência, observando-se em períodos críticos ligados a influências específicas que são fornecidos pelos *journals* de hoje. Não foram produzidas teorias consistentes sobre risco de crédito nos últimos anos e artigos semi-

nais como [Modigliani e Miller \(1958\)](#) ainda são considerados conceitos fundamentais para novas pesquisas.

2.5 Conclusões

A área de risco de crédito tem sido cada vez mais estudada por pesquisadores e praticantes do mercado. O interesse pelo tema é claramente justificado, uma vez que perdas financeiras de qualquer intensidade são indesejadas e num cenário de altos volumes podem causar mudanças de perspectivas, contágios, eventos de *default* e até mesmo falências. Esta pesquisa preocupou-se em analisar de maneira sistemática o que foi divulgado sobre o assunto no ambiente científico nos últimos quinze anos.

Os resultados demonstraram aspectos relevantes dos oitenta e três artigos pesquisados, em particular as suas semelhanças, contextualização e aplicabilidade por meio dos resumos, análises metodológicas e abrangência de estudos. Dentro dessa perspectiva, conforme a [Figura 2.1](#), constatou-se que o tema vem crescendo, mas as aplicações ainda concentram-se em modelagem de preditores e aplicações em derivativos; também, capital econômico, exposição ao *default* e LGD são potenciais áreas de crescimento, principalmente esta última, que é considerada pelos autores como o assunto mais relevante, mas a falta de dados limita a sua empregabilidade em estudos empíricos; os estudos teóricos possuem sofisticação matemática e sua argumentação propicia o interesse de pesquisas futuras e, portanto, são bastante citados.

Este trabalho acrescenta importantes resultados à literatura acadêmica, de modo que indica alguns *gaps*, conforme apresentados na [Seção 2.4](#), que devem ser observados e podem ser resumidos nos seguintes apontamentos:

1. O conceito de “Risco de Crédito” é muito associado a contágios;
2. Pouco se estuda a respeito do montante de perdas, tanto como requisitos de capital quanto capital recuperado devido a eventos de *default* e do tamanho da exposição a elas, enquanto os modelos de previsão de falências são mais frequentes na literatura; e,
3. As análises teóricas possibilitam o crescimento da área e os estudos mais recentes como, por exemplo, [He e Xiong \(2012\)](#) e [Veronesi e Zingales \(2010\)](#) demonstram tal interesse por parte dos pesquisadores.

Embora se tenha contribuído com essa sistematização de literatura e apontado direções para os estudos futuros na área de risco, é preciso destacar que futuras sistematizações poderiam ser realizadas visando identificar qual é a verdadeira rede de ligações por trás do mapa de citações ou da análise bibliométrica visto que não trata-se neste trabalho

do problema referente a auto-citação. Possivelmente, ferramentas ou índices como o de difusão da área de redes complexas possam ser empregados para esse fim.

3 Capital Econômico e *Ratings*: Análise e Requisitos Mínimos

O risco é um elemento básico dos negócios, pois a rentabilidade de qualquer atividade econômica envolve riscos (STOIAN; BALAN, 2012; KANAS, 2014). No entanto, a possibilidade de risco não significa que ele pode ser ignorado e investimentos diversificados podem ser feitos com diferentes graus de risco, assim é de se esperar que os resultados obtidos serão variáveis (OJO, 2010). Controles específicos podem ser necessários para se fazer cumprir diferentes tipos de risco por uma organização. Estudos anteriores têm enfatizado a importância da gestão de risco para as empresas dos segmentos financeiros e não financeiros (FREEMAN et al., 2006; STOIAN; BALAN, 2012).

Durante a crise financeira de 2008 que afetou o setor financeiro, bem como outras empresas, a área de risco foi o foco de uma análise cuidadosa, a fim de obter quantificações mais precisas de risco, nomeadamente o risco de crédito (OJO, 2010; HAQ; HEANEY, 2012; SHEN et al., 2012; LOU; YIN, 2014). As instituições tornaram-se cientes de que melhores estimativas de risco fornecem maior controle sobre seus efeitos e várias estratégias podem ser empregadas em determinadas circunstâncias (BAG; JACOBS Jr., 2011). Em particular, de acordo com Bade et al. (2010), a crise mostrou que os modelos de risco de crédito utilizados para a gestão de carteiras teve um grau de transparência relativamente pobre, ou seja, os estimadores produzidos por tais modelos não eram claros (ou mesmo consistentes, como mencionado por Neagu et al. (2009), Jokivuolle e Peura (2010), Bade et al. (2011), JACOBS Jr. (2010)).

A pesquisa na área de risco de crédito é relativamente recente (ERICSSON; RENAULT, 2006). No entanto, no final de 1990, Gordy (2000) sugeriu que avanços importantes foram feitos na modelagem de risco de crédito a nível de carteira. Mais recentemente, Giese (2005) indicou que um modelo de risco da carteira de crédito é extremamente importante porque o risco de crédito é a maior contribuição para o aumento de capital econômico em bancos.

Após os acordos de Basileia, determinou-se as exigências de capital mínimo como um dos instrumentos mais importantes para medir o risco de crédito. As instituições financeiras tentaram desenvolver modelos eficientes para os seus parâmetros e tiveram como objetivo minimizar o capital necessário e ou maximizar os lucros, ou seja, atuar em conformidade com as diretivas acordadas enquanto satisfazem seus acionistas. Tais regulamentos ajudaram as empresas a determinarem os seus próprios modelos, bem como a intensificação da investigação científica em mais de uma área de estudo no setor financeiro.

As variáveis básicas necessárias para desenvolver um modelo de risco de crédito

são (ALTMAN, 2006): (i) a probabilidade de *default* (conhecida como PD); (ii) LGD (conhecida por *loss given default*), que é igual a um menos a taxa de recuperação (RR) em caso de inadimplência; e (iii) exposição à inadimplência (EAD). A produção e a manipulação dessas variáveis são explicadas em maiores detalhes nas seções seguintes. Altman (2006) também afirmou que tem havido muitos estudos anteriores relacionados com as estimativas de PD , mas poucos têm considerado a estimativa de RR e a relação entre esses componentes. Ainda de acordo com Altman (2006), a PD está relacionada com o risco sistêmico, ou seja, a fatores relacionados com o mercado. Além disso, os modelos mais comuns têm utilizado a RR como uma variável que depende de fatores idiossincráticos, ou seja, métricas obtidas a partir de dentro da empresa, e, portanto, eles não dependem da PD .

Em particular, Jorion e Zhang (2009) afirmaram que a quantificação PD , LGD e EAD podem ser usadas para inferir sobre o capital econômico, em que a soma dos fundos detidos por uma instituição deve aumentar para absorver uma grande perda ao longo de um determinado horizonte de tempo com um nível de confiança elevado. Na forma tradicional de criação de capital econômico, presume-se que a taxa de LGD (igual a um menos a RR) é conhecida e não estocástica.

Ao criticar tal postura conservadora, Bade et al. (2011) observaram que estudos anteriores e a prática bancária corrente não mencionam várias propriedades de risco de crédito. Na verdade, PD , RR e suas correlações são muitas vezes modeladas como constantes, eliminando assim a sua aleatoriedade. Além disso, os parâmetros condicionais, tais como recuperações, que estão condicionados à ocorrência de inadimplência, são modelados utilizando modelos de regressão linear incondicionais com o método dos mínimos quadrados ordinários, que não considera a condicionalidade, e isso pode levar a um viés nos parâmetros estimados.

É importante ressaltar que o foco maior em estudos de risco de crédito se justifica, porque há falta de abordagem coerente que seja aceita teoricamente, e no mercado como um todo. Este é um problema de pesquisa muito interessante que afeta a sociedade enormemente e seu estudo ganhou terreno nos últimos anos, principalmente devido aos regulamentos por parte das instituições financeiras.

As agências de *rating* também realizam estudos abrangentes a cada ano, a fim de organizar as empresas sob um método específico de acordo com a sua única exposição ao risco de crédito. Assim, essas agências consideram os eventos de inadimplência que ocorreram ao longo do período e conduzem uma análise para cada grupo de risco, em que cada um dos grupos está associado a um certo nível de risco aceitável.

Levando isso em conta, o objetivo do estudo desenvolvido neste capítulo é determinar o volume de capital econômico disponibilizado por uma instituição financeira utilizando um modelo interno baseado no risco para estimar o risco de crédito, enquanto considera a qualidade de crédito do tomador de um empréstimo e, com base numa avalia-

ção por agência de classificação de risco da instituição financeira para este volume, como resumido na Figura 3.1. Tal abordagem permite que a instituição de crédito utilize a transação para melhorar a sua própria classificação, ao mesmo tempo minimizando o capital regulamentar. Para tanto, é empregado o mesmo método aplicado por [Sundmacher e Ellis \(2011\)](#), mas usando dados de outras fontes, bem como *PD* e *LGD* a partir de dois períodos específicos (1998 e 2002). Considera-se também a busca de uma classificação de risco melhorada pelas instituições financeiras, em que os mutuários têm uma menor *LGD* em relação a uma classificação de nível mais baixo, e, portanto, os requisitos mínimos de capital permanecem os mesmos.

Tendo esse objetivo em mente, o contorno da presente investigação sobre o capital econômico é o seguinte: na Seção 3.1, revisa-se pesquisas anteriores nesta área, incluindo as diretrizes de controle de risco estabelecidas por organismos internacionais de regulação, os modelos usados para medição de risco em ambientes profissionais e também em material acadêmico, bem como a importância da gestão de risco em todas essas áreas. A Seção 3.2 explica o método adotado com o objetivo de reduzir o capital econômico exigido do credor. Na Seção 3.3, mostra-se que os resultados obtidos utilizando tal método têm propriedades interessantes, como muito mais baixos requisitos de capital econômico para os credores em que a perda devido a incumprimento (comumente tratada por *loss given default*, ou *LGD*) está acima da média para a sua classificação sob vários critérios sujeitos a ajustes pelo credor. Na Seção 3.4, discute-se os resultados das simulações e, também, apresenta-se sugestões para melhorar os resultados obtidos.

3.1 Revisão da Literatura sobre Capital Econômico e seus Determinantes

O termo “crédito” está relacionado com a confiança e uma forma de mensurar essa confiança é medir o risco envolvido na situação ([DAS; TENG, 2001](#)). Em termos financeiros, [Stoian e Balan \(2012\)](#) argumentam que o crédito pode ser tratado como uma soma emprestada para alguém na qual é esperado que se devolva depois de um determinado período. Assim, o crédito está relacionado com o tempo e com a relação de confiança entre as partes envolvidas. Uma vez que uma soma de dinheiro está envolvida, é possível que o credor (quem fornece crédito) exija uma compensação mínima em troca desta confiança ([GLAESER et al., 2000](#)).

Se houver a possibilidade de interromper essa confiança, é claro que há a incidência de risco ao dar a alguém uma certa quantia, esperando para recebê-la na totalidade (ou devidamente compensados) após o período acordado. Este elemento imprevisível está associado ao risco de crédito. [Neal \(1996\)](#) define “Risco de Crédito” como a probabilidade de um devedor não cumprir o compromisso de pagar os empréstimos de um banco

ou dívidas. Portanto, medir esse risco pode fornecer informações sobre prováveis perdas, permitindo assim que um agente financeiro avalie melhor a sua compensação. Além disso, [Stoian e Balan \(2012\)](#) definem que o risco de crédito como sendo o risco atual ou futuro dos lucros e do capital impactado por falhas devido ao incumprimento de uma dívida ou de obrigações contratuais.

[Altman et al. \(2005\)](#) afirmam que o risco de crédito tem afetado mais fortemente os acordos financeiros; assim, devem ser considerados durante todas as transações que tentam gerenciá-lo para reduzir as perdas. Portanto, o gerenciamento fornece alternativas para reduzir os riscos com base em ajustes na alocação de fundos ou de instrumentos de proteção (*hedge*), com o objetivo de não fornecer crédito a uma empresa que tem riscos desnecessários.

Na pesquisa acadêmica, [Ericsson e Renault \(2006\)](#) observam que o risco de crédito tem estado sob maior escrutínio desde o estudo seminal de [Merton \(1974\)](#). [Stoian e Balan \(2012\)](#) confirmam as conclusões de [Ericsson e Renault \(2006\)](#) e indicam que a análise de risco de crédito e sua previsão têm sido objetos de intensa pesquisa desde os anos 1970. No entanto, essa tarefa tem-se demonstrada ser difícil. [Lai e Soumaré \(2010\)](#) acrescentam que o risco de crédito é um dos principais desafios enfrentados pelos bancos e outros credores.

Além disso, [Lai e Soumaré \(2010\)](#) enfatizam que a gestão de riscos é uma tarefa crucial para as corporações em todo o mundo. Em particular, [Altman \(2006\)](#) relata que a gestão de risco de crédito tem recebido muita atenção de economistas, dos supervisores bancários, dos reguladores e dos profissionais do mercado financeiro. Como uma consequência possível, de acordo com [Schuermann \(2004\)](#), a gestão de risco de crédito é agora comum em grandes instituições financeiras, onde os procedimentos de controle são necessários para reduzir as perdas potenciais devido à inadimplência.

Para facilitar a gestão de riscos eficaz, [Stoian e Balan \(2012\)](#) destacam que é importante incluir aspectos de risco de crédito do ponto de vista operacional geral, bem como o risco associado a um mutuário porque as estratégias com base na avaliação da contraparte são calculadas considerando a probabilidade de incumprimento.

Durante a última década, os bancos e as companhias de seguros têm feito investimentos consideráveis na concepção e implementação de sistemas de gestão de risco. No entanto, a crise financeira mostrou claramente que os modelos produzidos são insuficientes para detectar problemas, aumentando assim a pressão sobre as instituições financeiras e órgãos reguladores. Como resultado, estas questões têm produzido um ambiente desafiador, o que tem obrigado os administradores nacionais e internacionais, e outros órgãos, a reconsiderar todos os conceitos empregados, bem como os modelos. Em particular, os modelos de risco de crédito foram submetidos a tal processo de análise crítica devido à dinâmica de eventos ([GORDY, 2000](#)).

Neal (1996) observa que inúmeros métodos têm sido utilizados para o gerenciamento de risco de crédito. Nos últimos anos, uma abordagem alternativa de gestão de risco de crédito tem incidido sobre a venda de ativos com um maior risco de crédito. De acordo com o Castermans et al. (2009), a validação desses métodos é uma parte crucial da gestão de risco de crédito, mas apenas uma abordagem muitas vezes é usada para avaliar múltiplas restrições nos modelos empregados.

A dificuldade de lidar com o risco de crédito está relacionado à sua análise quantitativa. Botha e Vuuren (2009) mostraram que o risco de crédito é uma medida complexa, em que a repartição de perdas de crédito institucionais é altamente assimétrica, com formulação matemática que às vezes são bastante refinadas (por exemplo, usando cópulas para determinar a dependência entre variáveis aleatórias) para explicar a relação entre o ambiente econômico e as somas dos empréstimos, que envolve a diferenciação de ativos da equivalência patrimonial e as correlações de inadimplência, implicando, assim, que há vários parâmetros de adicionais ligados ao risco de mercado (por exemplo, a perda em caso de *default*, probabilidade de *default* e exposição ao *default*).

Na próxima seção, explicam-se tais regras e os seus efeitos sobre as partes interessadas, incluindo as fraquezas comuns dos modelos utilizados.

3.1.1 Regulação

Segundo Botha e Vuuren (2009), os acordos de Basileia em si não representam legislação definitiva, ao invés disso representam diretrizes para “melhores práticas globais”. Tais medidas foram elaboradas e executadas por representantes dos principais bancos centrais. No entanto, essas orientações servem como fatores limitantes das atividades bancárias, e assim o cumprimento destas regras é um pressuposto básico da participação de uma instituição financeira no mercado, igualando assim os riscos assumidos e fornecendo pontos de referência úteis tanto para a gestão de risco quanto para o acompanhamento da atividades bancárias em todo o mundo. Por conseguinte, um conjunto necessariamente restrito de modelos foi desenvolvido para cobrir todas as possibilidades de risco enfrentadas pelas instituições financeiras em todo o mundo.

Botha e Vuuren (2009) observam que o acordo de Basileia I estava preocupado apenas com o risco de crédito, mas posteriormente preocupou-se também com o risco de mercado, uma vez que o primeiro foi considerado excessivamente punitivo em alguns aspectos e muito suave em outros. De acordo com o Altman et al. (2005), na sequência de recentes tentativas por parte do Comitê da Basileia para a Supervisão Bancária (CBSB) para alterar a tabela de adequação de capital por meio da apresentação de novas exigências em termos de capitais sensíveis ao risco, mais atenção tem sido dedicada ao problema da medição do risco de crédito por este organismo internacional regulatório, bem como por acadêmicos e um grupo de instituições financeiras.

De acordo com o [Das \(2007\)](#), o acordo de Basileia II aumentou o foco no risco de crédito, em que uma abordagem baseada em classificações foi substituída por uma forma relativamente adequada, com um aumento da consideração das contrapartes que utilizam modelos internos. A principal base conceitual de Basileia II está relacionada com uma consideração explícita de correlações em risco total de uma carteira, proporcionando assim uma melhor demonstração da influência de riscos correlacionados sobre requisitos de capital.

O modelo básico de Basileia II para o cálculo do capital mínimo exigido especificado internamente pelos bancos é muito simples, somente se mede as perdas sistemáticas em uma carteira de crédito, ou seja, as perdas na carteira devido a influências externas e, portanto, não podem ser diversificadas ([GIESE, 2005](#)). [Das \(2007\)](#) também critica esse modelo, pois não considera o risco da carteira específica, que tende a ser muito diferente de acordo com a natureza de cada instituição, mesmo quando se considera a classe de ativos, alavancagem e maturidade semelhante.

[Botha e Vuuren \(2009\)](#) mostram que os impactos dos métodos para calcular o risco de crédito fornecidos no Basileia II, ao calcular o capital dos bancos, ainda são desconhecidos, e estudos são necessários para confirmar a sua exactidão, submetendo-os a testes empíricos para demonstrar sua eficiência no cálculo de risco.

A adequação do modelo utilizado é a questão principal, pois determina o capital mínimo exigido para a proteção de riscos por parte dos bancos. [Das \(2007\)](#) propõe o tradicional modelo de valor em risco (*VaR*) como um sistema de informação para os riscos encontrados em operações, em que a distribuição de perda é modelada explicitamente e o resultado obtido é a melhor estimativa de adequação de capital, desde que os cálculos envolvidos e os pressupostos de modelagem sejam razoavelmente precisos. No entanto, isso não é tão simples na prática.

O Basileia II concordou que as instituições podem empregar três modelos para avaliar os requisitos mínimos de capital: o modelo padrão, utilizando o mesmo método empregado em Basileia I; o modelo interno de abordagem do risco (conhecido como modelo *IRB*), que permite aos bancos desenvolver as suas próprias fórmulas, embora sob supervisão; e o avançado *IRB*, que é um tratamento mais sofisticado de medição de risco, semelhante ao de base *IRB*. [Das \(2007\)](#) explica que a mudança para a abordagem *IRB* deu aos bancos maior flexibilidade quando se emprega várias hipóteses para estimar parâmetros e para satisfazer suas expectativas internas relacionadas aos níveis de capital. Para evitar a obtenção de estimativas que são tendenciosas a seu favor, as instituições financeiras devem considerar o seguinte:

1. Consciência de inspeções mais intensas porque a minimização do capital econômico deve respeitar regras predefinidas;
2. Consciência de que a abordagem *IRB* reconhece que os bancos têm empregado ca-

pital baseado em risco por quase duas décadas, e assim essas regras não parecem ser obstáculos à criação e manipulação de modelos mais adequados do que os utilizados no mercado; e,

3. Consciência de que essa nova abordagem é muito mais consistente com a gestão interna de risco em termos de tornar o negócio mais confiável e consistente porque as instituições terão como objetivo a ser cumprido o acordo de Basileia II.

No entanto, tais propostas visam reduzir os regulamentos internos e os custos de gestão de risco a longo prazo, embora no curto prazo, seja caro para produzir os relatórios exigidos nos termos tanto de Basileia I, quanto de Basileia II, lembrando que o risco de crédito, conforme definido anteriormente por [Neal \(1996\)](#), especifica perdas prováveis ou do não pagamento de um crédito concedido para o mutuário.

[Schuermann \(2004\)](#) afirmou que Basileia II permite que as organizações bancárias com atividades internacionais calculem suas necessidades de capital de risco de crédito usando um modelo *IRB*, e estejam sujeitos a revisão pelo órgão supervisor. [Das \(2007\)](#) explicou que Basileia II considera dois tipos de perda para determinar o risco de crédito: (a) perda esperada (*EL*) e (b) a perda de inesperada (*UL*). Assim, quaisquer noções de capital regulamentar ou capital econômico devem estar relacionadas com os conceitos de *EL* e *UL*.

A subseção seguinte discute o modelo de Basileia II de base para o capital econômico baseado no *EL* e *UL*, e seus pressupostos.

3.1.2 Capital Econômico e o Modelo de Mensuração

De acordo com o [Altman et al. \(2005\)](#), modelos de risco de crédito podem ser divididos em três classes principais: (1) “primeira geração” de modelos estruturais; (2) “segunda geração” de modelos estruturais; e (3) os modelos de forma reduzida. A primeira classe é baseada no modelo de [Merton \(1974\)](#), em que o patrimônio da sociedade desempenha um papel importante, bem como o risco de inadimplência. Também foi afirmado que a intuição por trás desse modelo é simples, ou seja, um evento de *default* ocorre quando o valor de mercado de ativos de uma empresa é abaixo do valor do seu passivo. Muitos novos modelos foram criados com base neste de Merton (ver [Altman et al. \(2005\)](#)).

A segunda categoria inclui também modelos baseados em [Merton \(1974\)](#), mas reconsidera várias suposições: que a inadimplência pode ocorrer antes de expirar um passivo, se o evento padrão ocorrer quando o endividamento do mutuário for maior do que os seus ativos; que a *RR*, em caso de inadimplência, é exógena e não depende do valor patrimonial de uma empresa; e que a *LGD* não depende *PD* se o pressuposto anterior é válido ([ALTMAN, 2006](#)). Finalmente, de acordo com [Altman \(2006\)](#), modelos reduzidos

assumem que a RR não depende do PD e que o modelo é capaz de risco de crédito de preços com base em processos estocásticos. A diferença entre a forma estrutural e a forma reduzida está relacionada com a previsibilidade do evento predefinido, em que a diferença é maior em modelos de forma reduzida.

Devido a essa divisão, vários modelos são usados por corporações e na academia. Como discutido anteriormente, os modelos definidos no âmbito de Basileia II são muito simples e podem permitir que os bancos aloquem uma quantia maior de capital que o necessário. Para melhorar esses modelos, as agências de *rating* e os bancos desenvolveram os seus próprios modelos relacionados à gestão de riscos. No que diz respeito às agências de notação, podemos considerar *Standard & Poors* e *Moody's* como as agências de classificação de risco de crédito principais. Entre os bancos, *JP Morgan* é o criador do *CreditMetrics* e o *Credit Suisse* desenvolveu o *CreditRisk⁺*. No entanto, [Sundmacher e Ellis \(2011\)](#) afirmam que, devido à falta de uma teoria unificada, tem havido uma explosão no número de métodos empíricos utilizados para prever a falha de negócios em diferentes mercados.

Usando o modelo básico de Basileia II, o capital mínimo exigido pelo risco de crédito é suportada pelo EL e UL . De acordo com o [Crouhy et al. \(2000\)](#), o cálculo de EL é baseado em três variáveis: PD , LGD , e EAD . Sob essa definição, EL pode ser descrita de acordo com a Equação 3.1.

$$EL = PD \times LGD \times EAD \quad (3.1)$$

onde:

PD é a probabilidade de *default*;

LGD é a *loss given default*, ou melhor, a perda dada a inadimplência; e

EAD é a *exposure at default*, ou seja, a exposição ao *default*.

O modelo utilizado no presente estudo assume que PD e LGD são fatores independentes, fixando explicitamente a LGD e assumindo que EAD é igual a 1, sem perda de generalidade. Assim, o valor de EL é expressa em termos de PD e LGD exclusivamente. Dado que a distribuição das perdas é baseada apenas na distribuição de probabilidade da variável PD , e que o resultado dessa variável é determinado por um evento de Bernoulli (há ou não o incumprimento), EL é a média da distribuição e (UL) representa a medida de desvio padrão para EL (para mais detalhes sobre esse desfecho, consulte [Ong \(1999\)](#) e [Mora \(2012\)](#)). Portanto, de acordo com os critérios mais simples de Basileia II, pode-se concluir que a UL é obtida tal como descrito pela equação 3.2.

$$UL^2 = Var(EL) = LGD^2 \times PD(1 - PD) = PD \times LGD \times (LGD - PD \times LGD) \quad (3.2)$$

Substituindo 3.1 em 3.2, UL pode ser expressa em termos de EL , o que pode ser escrito conforme a Equação 3.3.

$$UL^2 = EL \times (LGD - EL) \quad (3.3)$$

O capital econômico é determinado com base em uma proporção de UL porque o risco de crédito está previsto com base na quantidade precisa do capital investido que a instituição financeira não espera perder. A Figura 3.2 ilustra a distribuição de perda para uma carteira de ativos, em que as medidas que compõem parte da medida de capital econômico, ou seja, EL e UL , são representados como uma visualização gráfica com base na frequência de as perdas que ocorrem.

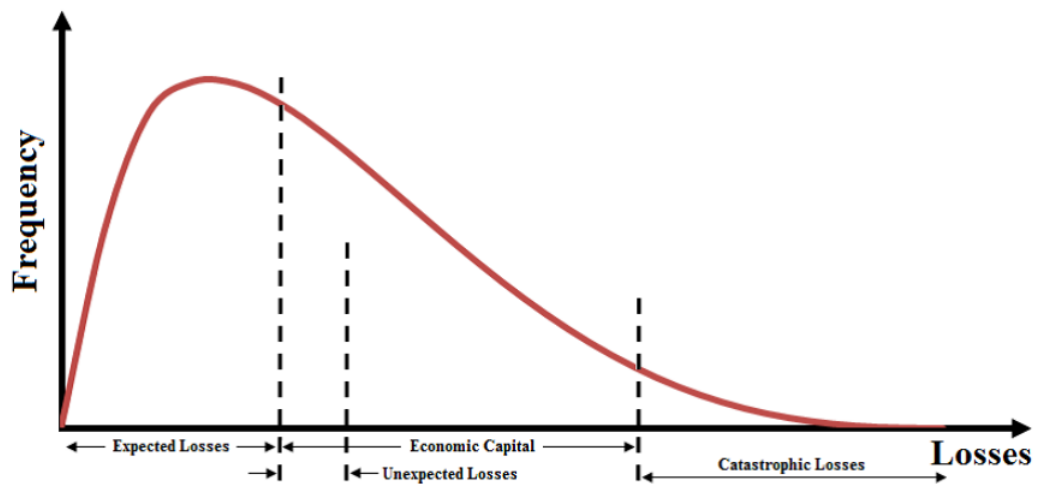


Figura 3.2: Forma de distribuição das perdas em termos de frequência. Em estudos financeiros, essa curva é útil para descrever o comportamento de perdas em eventos de inadimplência. As expectativas de perdas mais elevadas aumentam à medida que a frequência diminuiu, mas apenas para perdas esperadas muito elevadas. O capital econômico pode ser visualizado como a proporção da UL para além do nível de EL .

Dadas tais considerações, a única maneira de minimizar o capital econômico é encontrar as medidas de PD e LGD que vão levar a esse resultado, pois são os critérios básicos relacionados às perdas. Com base nessa dificuldade específica, os métodos para estimar cada perda também foram concebidos com a mesma finalidade. Esposito (2011) explica que os principais componentes de risco podem ser adaptados de forma adequada para uma abordagem baseada em modelos IRB a fim de incluir métodos específicos para adequar à estrutura de PD , à distribuição de LGD e ao cálculo de EAD .

3.1.3 *Ratings* de Empresas de acordo com a Exposição ao Risco de Crédito

Com o intuito de determinar a qualidade das empresas que realizam as obrigações de crédito, as agências de classificação de risco (por exemplo, a *Fitch*, *Standard & Poors* e *Moody's*) empregam seus próprios métodos para listar empresas de uma forma ordenada, proporcionando ao mercado uma ferramenta adicional para estudar bons e maus desempenhos.

[Boot et al. \(2005\)](#) afirmam que muitos participantes do mercado consideram notações de risco um fator importante em sua análise, também sugerem que isso mudou o comportamento dos investidores, ou seja, as empresas devem considerar mais um indicador de desempenho relacionado aos riscos das operações de crédito e a influência que isso tem no ambiente externo.

As agências preparam relatórios sazonais sobre o comportamento de cada nível de classificação e suas alterações, bem como os valores de *PD* por nível de classificação devido a eventos de inadimplência entre as empresas incluídas em cada um desses níveis.

3.2 Simulação Computacional

O presente estudo tem por objetivo analisar mudanças no capital econômico quando uma instituição pretende entrar em uma transação de crédito e adotar uma melhor posição de classificação de risco considerando a posição atual da contraparte. Isso é possível quando o capital econômico é obtido por meio da aplicação dos dados do mutuário no seu cálculo. De acordo com o [Sundmacher e Ellis \(2011\)](#) e [Ong \(1999\)](#), o capital econômico está associada com a contraparte em um determinado nível de confiança e horizonte temporal. O nível de confiança é definido precisamente pela qualidade de crédito associado com a classificação desejada pelo credor, que está diretamente relacionado com a sua *PD*. Assim, [Sundmacher e Ellis \(2011\)](#) identificaram esse valor como a taxa de solvência, uma vez que ter uma taxa de inadimplência mais baixa significa que a empresa goza de maior credibilidade no mercado, e este valor se torna cada vez mais perto de 1 quando o credor procura uma melhor classificação.

Dado que a distribuição das perdas se encaixa melhor com uma distribuição Beta, a medida de *EL* adquire propriedade de média da distribuição (μ). No caso da distribuição beta, a função densidade de probabilidade é baseada numa função gama ($\Gamma(X)$) e a sua forma é determinada pelo valor de dois parâmetros chamados de α e β . A Figura 3.3 mostra o formato da distribuição beta usando, por exemplo, os parâmetros $alpha = 7$ e $beta = 2$. A função densidade de probabilidade do modelo Beta (*PDF*) é expressa pela equação 3.4.

$$PDF(x) = \frac{\Gamma(\alpha + \beta)}{\Gamma(\alpha) \times \Gamma(\beta)} x^{\alpha-1} \times (1 - x)^{\beta-1} \quad (3.4)$$

onde:

$\Gamma(\cdot)$ representa a função *Gamma*;

x , na prática, determina o tamanho da perda;

α é o parâmetro que influencia a forma da distribuição; e

β é o segundo parâmetro que determina o comportamento da distribuição (MORA, 2012).




Figura 3.3: Gráfico da função densidade de probabilidade (*PDF*) da distribuição Beta para os parâmetros $\alpha = 2$ e $\beta = 5$, como um exemplo. Esta *PDF* pode substituir a distribuição de perdas quando os parâmetros α e β são calibrados de forma adequada. Este tratamento é necessário porque a média e o desvio padrão que determinam a distribuição teórica, *EL* e *UL*, respectivamente, podem ser calculados.

Ao aplicar os conceitos médias e variância para uma distribuição em curso, as medidas de *EL* e *UL* podem ser definidas por uma aproximação à distribuição Beta. O resultado é mostrado na Equação 3.5.

$$EL = \mu = \frac{\alpha}{\alpha + \beta} \quad (3.5)$$

A variância (UL^2) é determinada com base nos parâmetros da distribuição, como mostrado na Equação 3.6.

$$UL = \sigma^2 = \frac{\alpha\beta}{(\alpha + \beta)^2(\alpha + \beta + 1)} \quad (3.6)$$

Usando as equações 3.5 e 3.6, pode-se obter valores distintos de α e β baseado

nos valores de UL e EL . Assim, tais medidas são obtidas da seguinte forma,

$$\alpha = \frac{(1 - EL) \times EL^2}{UL^2} - EL \quad (3.7)$$

e

$$\beta = \frac{\alpha}{EL} - \alpha. \quad (3.8)$$

As medidas de EL podem ser obtidas por meio da revisão dos relatórios das agências de *ratings*, que contêm valores de PD . Os dados de PD empregados em nossas simulações foram baseados em relatórios anuais da *Moody's* (1999, 2003), como mostra a Tabela 3.1. Os valores de LGD são mais difíceis de se encontrar (FRYE; JACOBS Jr., 2012), uma vez que esses dados são comunicados raramente, além da sua incidência ser difícil de se medir (HUANG; OOSTERLEE, 2011). No entanto, a *Society of Actuaries* (2002, 2006) emitiu relatórios fornecendo um quadro suficiente de medidas de LGD destinadas a preparar esta simulação no mesmo período de coleta de dados da PD . A Tabela 3.1 mostra os dados de LGD extraídos a partir dos relatórios acima mencionados.

<i>Rating</i>	1998		2002	
	<i>PD</i>	<i>LGD</i>	<i>PD</i>	<i>LGD</i>
AAA	0.00 %	n.f. %	0.00 %	n.f. %
AA	0.03 %	75 %	0.02 %	33 %
A	0.01 %	17 %	0.02 %	26 %
BBB	0.12 %	25 %	0.22 %	35 %
BB	1.29 %	29 %	1.28 %	29 %
B	6.47 %	37 %	6.51 %	39 %

Tabela 3.1: Dados coletados da Probabilidade de *default* (PD) a partir de relatórios da *Moody's* baseados nas médias acumuladas nos últimos 20 anos em cada período. Nota: a classificação AA apresenta maior PD do que a classificação A em 1998. LGD dados coletados a partir dos relatórios da *Society of Actuaries* para os anos de 1998 e 2002 para as mesmas classificações dos relatórios da *Moody's*. A classificação AAA não foi apresentada para os anos dessa análise. **Fonte de dados:** *Moody's Investors Service* (1999), *Moody's Investors Service* (2003), e *Society of Actuaries* (2002), *Society of Actuaries* (2006).

A Tabela 3.1 destaca o declínio em relação a LGD referente a classificação AA a partir do primeiro para o segundo período. Essa mudança causou alterações importantes nos valores de cálculo econômico, que foram exploradas com base nos resultados das simulações. Carey e Gordy (2004) comentaram que a LGD foi muito alta em 1998 e isso não é comum. Em relação ao período entre 1999 e 2002, que é considerado um período de crise financeira, Altman (2006) explica que, em tempos de dificuldades econômicas, o valor de LGD pode flutuar devido à tendência de aumento de eventos de inadimplência.

Além disso, essa Tabela 3.1 também sugere a existência de anomalias, no qual, por exemplo, os níveis de PD e LGD associados a classificação AA são maiores do que aqueles para o *rating* A. Há uma série de explicações possíveis para tal fenômeno. Em primeiro lugar, Caouette et al. (2008) sugerem que a hierarquia das taxas de inadimplên-

cia, especialmente em *ratings* de grau de investimento, não pode ser observada devido a eventos específicos, citando o caso de pedido de falência da Texaco em 1987 e do *default* dos títulos emitidos pela *WorldCom* em 2002. Corroborando com os dados empíricos utilizados nesse estudo, [Hanson e Schuermann \(2006\)](#) construíram intervalos de confiança para probabilidade de *default* usando dados da *Standard & Poor* de 1981 a 2002, que abrangem nosso período de investigação, e descobriram que é difícil distinguir os valores de *PD* entre *AA-* e *A+*.

Em segundo lugar, a estimativa de *PD* usando frequência de incumprimentos reais pode ser vulnerável ao número muito pequeno de empresas/*default* em classificações mais elevadas. A ocorrência de um *default* improvável em classificações mais elevadas, por exemplo *AA*, pode influenciar consideravelmente as estimativas de *PD* e *LGD*. [Carey \(1998\)](#) analisou dados de 1988 e 1992 e identificou que a taxa média de perda de classificação para empresas classificadas como *AA* foi maior do que para o *rating A*. De acordo com o [Carey \(1998\)](#), eventos graves para o nível *AA* causam às vezes um certo ruído devido ao pequeno número (3) de eventos de risco de crédito em comparação com a nota *A*, que apresentou um número mais elevado (10) de eventos de crédito. Também é importante destacar que os dados de *LGD* em uma classificação específica considera todas as perdas relacionadas a eventos de inadimplência reais e não a todos os eventos em uma amostra *a priori*. Portanto, dados de *LGD* estão condicionados a ocorrência de incumprimento e, especialmente para classificações mais elevadas com um pequeno número de observações, e, dessa forma, os dados empíricos podem estar sujeitos a uma característica muito distinta de um *default* específico.

Em terceiro lugar, a relação entre as notações e parâmetros de crédito, como *PD* e *LGD* podem não ser robustos ou até mesmo esperado. [Carey \(1998, p. 1372\)](#) argumenta que “nenhuma relação clara entre as gravidades da perda e as avaliações é evidente”. [FitchRatings \(2014, p. 11\)](#) afirma explicitamente que as limitações da escala de avaliação incluem o fato de que “*ratings* não preveem um percentual específico de probabilidade padrão ou perda esperada em qualquer período de tempo determinado”. Portanto, os dados empíricos e a metodologia de *rating* não devem relacionar-se diretamente com *PD* e *LGD*. Na verdade, [Altman e Rijken \(2004\)](#) e [Cantor \(2004\)](#) sugerem que as agências de *rating* são morosas para reagir a mudanças na qualidade do crédito de um mutuário que leva a falhas em medidas de curto prazo de *PD*.

Considerando tais condições, um credor irá avaliar as circunstâncias em que é possível obter uma vantagem competitiva, a fim de determinar a medida de capital mínimo exigido, respeitando Basel II de acordo com o seu modelo básico, obtendo assim uma melhor classificação com o mesmo volume de capital econômico.

No método proposto explicado neste capítulo e apresentado por [Sundmacher e Ellis \(2011\)](#), destaca-se a mudança na medida de *LGD* para os mutuários com níveis de classificação entre *A* e *B*, de forma que se forneçam soluções viáveis para os credores

com o objetivo de obter um aumento na qualidade do crédito. As medidas de capital econômico cumprem com essas alterações, que são determinadas pela proporção k e UL , como ilustrado na Figura 3.2. De acordo com o método detalhadamente descrito por Ong (1999), é possível ver que:

$$EC = k \times UL, \quad (3.9)$$

onde:

UL é a perda inesperada, expressa em termos de porcentagem. Essa medida é dada pela média de PD e LGD do devedor, de acordo com a sua classificação; e

k mede a UL do ponto de vista do credor para determinar o capital mínimo exigido.

No caso desse último, espera-se que possa melhorar a qualidade da classificação de risco de crédito com base na posição do mutuário, de modo que essa proporção de UL (o valor de US k) foi avaliada de acordo com uma distribuição aproximada da média de PD e variância do mutuário por meio da aplicação de dados fixados (apresentados na Tabela 3.1), inserindo-os nas Equações 3.1 e 3.3:

$$k = \frac{x - EL}{UL}, \quad (3.10)$$

tal que:

x é o valor exato relacionado com o volume de capital, onde $P(x \leq EL + k \times UL)$. O seu valor pode ser encontrado usando o inverso da função de distribuição cumulativa, isto é, $x = f^{-1}(P, \alpha, \beta)$. De acordo com o Sundmacher e Ellis (2011), a média de P é expressa em $1 - PD$ para determinar a solvência exigida pelo credor. É importante lembrar que PD é um valor extraído da classificação que o credor tem como objetivo, disponível na Tabela 3.1, enquanto EL e UL são dadas por dados do mutuário na Tabela 3.1. Neste caso, eles foram fixados para determinar α e β . Pelo contrário, UL a partir da Equação 3.9 é calculado para cada LGD , resultando em diferentes níveis de capital econômico para cada mutuário analisado.

Com base nessa formalização matemática, o capital econômico foi determinado para os credores avaliado nos níveis AAA, AA, A, BBB and BB e BB, em que os mutuários foram alocados para A, BBB, BB and B. No caso dos mutuários, a LGD varia entre 10% e 50% a fim de confirmar as dimensões de capital econômico para esses casos. Esta variação foi aplicada ao cálculo de UL empregado explicitamente na Equação 3.9. Note que tal variação não se aplica ao valor de k , no qual o valor de LGD foi fixado de acordo com a Tabela 3.1, considerando apenas informações sobre a classificação do mutuário.

Devido ao nível AAA de solvência, o valor de UL foi questionado porque os eventos de *default* são praticamente desconhecidos, o que prejudica o conhecimento de

LGD. Assim, essa situação exige que o capital econômico não mude com *UL*, mas em vez disso, dependa apenas de *EL* e a porcentagem de capital alocado (x) aplicado a uma proporção de *UL*, (k), que é computado por meio de recursos do mutuário.

Como o foco está direcionado para as medidas de risco de crédito e sua influência sobre as metas de classificação de instituição financeira, a questão da endogeneidade não é discutida em profundidade. Em primeiro lugar, esta pesquisa não testa comportamentos de regressão, que são mais suscetíveis a endogeneidade. É importante mencionar que as médias de *PD* e *LGD* foram coletadas a partir de duas fontes diferentes que adotam metodologias distintas. Em segundo lugar, se é uma preocupação que *PD* e *LGD* são influenciados por características de qualquer banco, muitos autores sugerem a utilização de variáveis com defasagem de um ano para obter estimativas dessas medidas, como proposto por Jeon e Wu (2014), Vithessonthi (2014), e Vithessonthi e Tongurai (2015). Além disso, Chalermchatvichien et al. (2014) examinaram a relação entre o banco, a assunção de riscos e a concentração da propriedade, que são variáveis semelhantes às apresentadas neste trabalho, e descobriram que seus resultados não foram influenciados por características não observáveis do banco. Embora se reconheça que a endogeneidade pode estar presente, acredita-se que este problema é atenuado à luz de Chalermchatvichien et al. (2014), Vithessonthi e Tongurai (2015), e Sundmacher e Ellis (2011) conseqüentemente.

A metodologia do estudo segue os passos representados na Figura 3.4.

3.3 Análise e Resultados

Os resultados apresentados na Tabela 3.2 e, também, ilustrados na Figura 3.5 refletem os valores de capital econômico requeridos para negócios com tomadores classificados no nível *A* e credores que desejam alcançar os níveis *AAA*, *AA*, *A* e *BBB*, com base em avaliações que utilizam dados recolhidos durante dois períodos diferentes: de 1998 e 2002 (dados dos relatórios da *Society of Actuaries* (2002, 2006) e relatórios da *Moody's* para os mesmos períodos 1999, 2003).

Várias questões importantes foram destacadas nestas simulações: uma comparação entre os dois períodos detectou um aumento sutil em *EC*, com maior ênfase na credores avaliados em *AA*, enquanto que o restante não foi percebido. Esse foi apoiado pela *LGD* para um credor com um *AA* classificação em 1998, que diminuiu abruptamente em relação a 2002, enquanto *PD* aumentado. A probabilidade de um requisito de fundos próprios mais baixo pode ainda ser encontrado para os credores que desejam uma classificação *AA* no caso de mutuários com um *LGD* acima 17% (em 1998), onde se torna necessário perto de 35% de capital regulamentar. No período seguinte, ou seja, de 2002, os resultados foram muito melhores porque o *A* de classificação *LGD* aumentada de um período para o outro, refletindo assim um requisito de capital de cerca de 61% para um

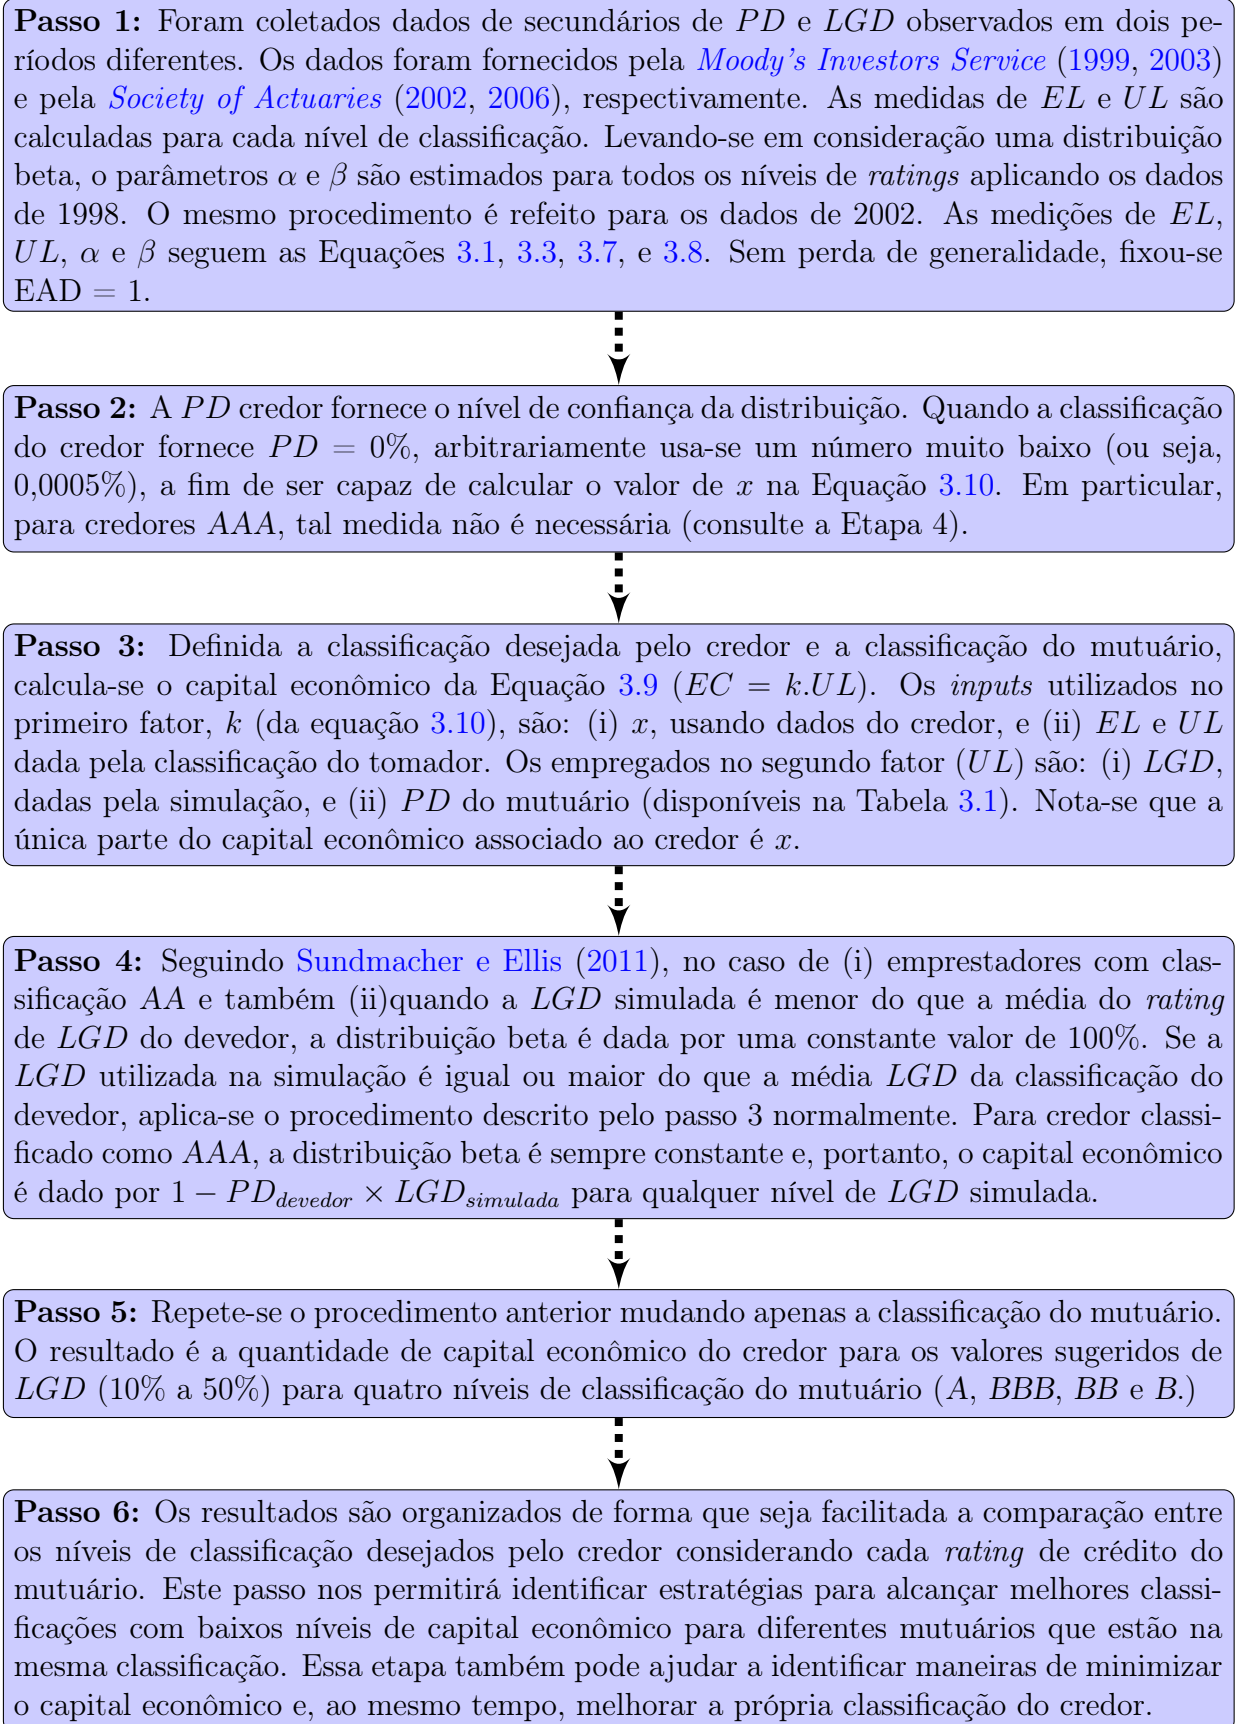


Figura 3.4: Descrição passo-a-passo do método aplicado neste capítulo.




Figura 3.5: Capital econômico para credor com objetivo de alcançar diferentes níveis de *rating*, baseado na simulação da *LGD* do tomador de *rating* A.

LGD de 26%. Em contrapartida, para metas mais baixas de *rating*, como *BBB*, os resultados refletiram valores abaixo dos 8% mínimo definido pelo CBSB em ambos os períodos (ALTMAN; SAUNDERS, 2001), que também foi o caso de instituições que desejava ser avaliado como *A* com os mutuários com um *LGD* abaixo 30%. Neste momento, surge uma oportunidade para os interessados em subir de classificação, ou seja, era possível para um credor para aumentar a sua classificação de risco de crédito no âmbito deste método simplesmente pela obtenção de mutuários de nível *A*, com uma *LGD* abaixo 30%. No entanto, não é indicado para emprestar a um Amutuário se o credor procura uma classificação mais elevada, como *AA*. O capital econômico mínimo é muito alto (perto de 34 %) em comparação com outras classificações desejadas antes (*A* e *BBB*). Além disso, este foi o único caso em que o capital econômico foi maior em 2002 em comparação com o período anterior.

Note que foi requisitado os mesmos 8% para atingir tanto o *rating* *BBB* como também para o nível *A*, o que significa que o capital econômico é o mesmo para tomadores com *LGD* menor do que 30%. Obviamente, o credor opta pela melhor posição de *rating* percebida sem necessariamente aumentar os requisitos de capital.

A Tabela 3.2 mostra análise similar para nível de *rating* alvo *BBB* do credor, a qual pode ser vislumbrada na Figura 3.6. Dessa forma, sua qualidade de crédito seria melhor ainda em termos de necessidade de capital regulatório. Isso ocorre por causa da classificação do tomador estar abaixo do valor empregado na situação anterior, que encontra-se descrito em colunas anteriores da mesma tabela.

Em uma simples inspeção da Tabela 3.2 quando os *LGD* valores para a *BBB* nível mutuário foram 25% e 35%, em 1998 e 2002, respectivamente, a janela de oportunidade para alcançar um *AA* classificação por um credor era uma tarefa mais complexa, isto é, o capital econômico aumentou para cerca de 75% em 1998 e para 93% em 2002. Apesar disso, os critérios mínimos de capital econômico seguiu a mesma tendência que a




Figura 3.6: Capital econômico para credor com objetivo de alcançar diferentes níveis de *rating*, baseado na simulação da *LGD* do tomador de *rating* *BBB*.

caso anterior, no qual caiu um nível de classificação, ou seja, para os mutuários com um *LGD* inferior a 30%, a classificação pode ser obtida com uma exigência de capital econômico de 8%. Aqui, a melhoria classificação exige uma diferença substancial em *LGD*. Mais especificamente, em 1998, o credor iria mudar um mutuário com *LGD* superior a 45% para outro, com *LGD* por perto 20% menor sem a necessidade de um incremento no capital econômico. O mesmo artifício foi menos viável em 2002, porque 93% do capital econômico era necessário para um mutuário com *LGD* entre 35% e 37% para alcançar um *rating* *AA*. Se o credor estava à procura de uma classificação para mudar de *BBB* para *A*, ele teria que encontrar um mutuário com uma *LGD* muito menor (cerca de 40% inferior).

Os resultados mais interessantes da simulação são confirmados na Tabela 3.2 e Figura 3.7. Um credor que desejar a classificação *BBB* através de uma transação com a mutuário de *rating* *BB* e com uma *LGD* mais de 16%, será necessário a mesma quantidade de capital econômico (quase 27%) quando almejar uma classificação *A* (em relação ao período de 1998; o conceito para 2002 é feito de forma análoga, mas para *LGD* superior a 19%, resultando em uma capital exigido próximo de 25%). Assim, porque o capital econômico é o mesmo em ambos os cenários, seria benéfico encontrar mutuários com uma *LGD*, pelo menos, 6% inferior, pois eles podem permitir uma classificação mais alta a ser alcançada. O mesmo poderia se aplicar a um aumento de *A* para *AA*, embora com uma mudança menor em *LGD*, ou seja, entre 42% e 46% em 1998, e entre 39% e 40% em 2002. Caso considere os valores fora deste intervalo, o credor deve procurar a classificação *AAA*. A vacância de capital necessário para alcançar *AA* ainda era possível quando se considera um mutuário com um *LGD* delimitada por 29%-31% para ambos os períodos.

Como mostrado na Tabela 3.2, os resultados concordam com os da parte anterior da tabela, ou seja, quando se observa uma *A* ou *BBB* classificação desejado. No entanto, a distância entre eles é de apenas 2% no início das simulações. Por exemplo, se o




Figura 3.7: Capital econômico para credor com objetivo de alcançar diferentes níveis de *rating*, baseado na simulação da *LGD* do tomador de *rating BB*.

credor poderia escolher entre dois mutuários, X ou Y, onde ambos são classificados como BB e *LGD* do X é de 10%, enquanto a *LGD* de Y é 12%, o credor pode almejar para si mesmo uma classificação A. Isso ocorre porque o capital econômico necessário para Y para alcançar a classificação BBB desejada (isto é 23,86%) é um pouco maior do que o necessário por X (23,74%), quando se busca uma classificação A. As alterações relacionadas com *LGD* tiveram maior amplitude e maior capital foi exigido, o que é evidentemente relacionado ao declínio da qualidade de crédito do mutuário. No entanto, a Figura 3.8 mostra mais claramente os resultados exibidos no final da Tabela 3.2.




Figura 3.8: Capital econômico para credor com objetivo de alcançar diferentes níveis de *rating*, baseado na simulação da *LGD* do tomador de *rating B*.

3.4 Conclusões

Os valores apurados de capital econômico demonstram que há uma oportunidade interessante para as instituições financeiras quando se considera a classificação de risco de crédito atribuído aos seus clientes a melhorar o seu próprio posicionamento com agências de *rating*, enquanto também não há necessidade de uma maior exigência de capital para atingir esse objetivo. Isto foi confirmado pela análise feita neste capítulo, no qual se mostrou que uma instituição financeira que emprestou a uma empresa nível *A* teve a oportunidade de melhorar a sua posição classificação e foi necessário apenas um baixo *LGD*. Nos casos em que *BBB* e *A* classificações foram desejados por um credor, deve notar-se que o capital necessário foi o mesmo ao longo de um intervalo adequado de *LGD* valores. Estas comparações foram visualizados com base nos resultados obtidos com a *BBB* mutuário, embora as janelas de oportunidade para *LGD* não eram muito frequentes. Isso demonstra o declínio no capital econômico exigido pelo limiar a *LGD* 's quando um credor desejar um *AA*, porque os mutuários com um *LGD* abaixo deste limite tinha propriedades inesperadas nesse grupo.

Para um *BB* mutuário, havia dois possíveis resultados estratégicos: um salto de capital econômico a *LGD* com a respectiva classificação na busca de uma *AA* ou usando a mesma reserva de capital para empresas com uma classificação mais elevada, mas com uma qualidade inferior de *LGD*. De acordo com a mesma lógica, para um *B* mutuário em comparação com *BB*, o raciocínio é semelhante ao tomador *BBB* em comparação com *A* e mudando as posições, ou seja, as janelas de oportunidade são análogas, mas menos frequente. No entanto, a medida capital econômico da classificação do mutuário demonstra que existe uma alternativa viável para as instituições financeiras que requerem uma classificação melhorada para si mesmos, porque isso iria obter melhores resultados. Assim, os gestores de risco podem avaliar as suas decisões de forma mais precisa com o objetivo de detectar tais situações entre suas alternativas de investimento ou concessão de crédito.

Os modelos de risco ainda são considerados um tema interessante e um enorme campo de estudo (STOIAN; BALAN, 2012). Nossa contribuição é baseada na verificação de arbitragens nos *ratings*-alvo, em que muitas vezes não é necessário incremento de capital econômico através de um estudo feito por Sundmacher e Ellis (2011), aplicando-se os dados de dois períodos diferentes. Então, se testou um método prático para avaliar uma opção de empréstimo que, além do retorno esperado e o risco envolvido, pode envolver a alavancagem de classificação da instituição de crédito, proporcionando assim uma melhor reputação no mercado e, possivelmente atraindo mais os investidores e/ou financiadores .

Uma questão importante a ser considerada neste estudo é a cooperação entre os parâmetros na determinação dos resultados das simulações porque *LGD* e *PD* tendiam a se mover na mesma direção; assim, ao especificar uma dessas variáveis e equilibrando a

outra (o que é provável de ocorrer na prática), o valor do capital econômico pode levar a conclusões específicas em aplicações práticas, dado que as empresas podem mudar suas próprias avaliações com base na posição do seu credor, que é extremamente interessante. No entanto, presume-se que a melhoria da qualidade de crédito é uma indicação de que a redução dos requisitos de capital irá aparecer no futuro por causa de melhores posições irá obter este benefício.

Algumas limitações deste estudo podem ser abordadas em pesquisas futuras. Em particular, o volume de *LGD* ainda é insuficiente para obter resultados com elevado impacto na comunidade acadêmica. No entanto, nosso estudo indica que as soluções para este problema pode fornecer informações úteis nesta área. A disponibilidade de dados *PD* tem melhorado, onde são relatados em intervalos suficientes para tratar do assunto, ou seja, por ano e por vezes mensal, mas esta ainda é considerado um intervalo muito pequeno, o que pode causar oscilações excessivas nem afirmações errôneas, assim, resultando em vários vieses. Outra limitação é observada pelo problema de endogeneidade. Para inserí-la em nosso modelo iria mudar a natureza da discussão, tornando-se sobre vários mutuários, e gostaria de convidar estudo da carteira de crédito, o que mudaria substancialmente o foco desta pesquisa. Sugere-se que isso poderia ser explorado em um futuro estudo sobre o nível da carteira de crédito, onde é possível considerar características de um banco. Uma pesquisa mais adicional pode ser possível com base neste estudo, tais como a avaliação do modelo básico, considerando a proporção de dependência entre *PD* e *LGD*, produzindo, assim, novas perspectivas.

LGD	A - Rated Borrower			BBB - Rated Borrower			BB - Rated Borrower			B - Rated Borrower							
	AAA	AA	A	BBB	AAA	AA	A	BBB	AAA	AA	A	BBB	AAA	AA	A	BBB	
1998	10%	100.00	100.00	8.00	8.00	17.21	16.93	8.00	8.00	99.87	99.87	17.21	16.56	99.35	99.35	25.20	21.83
	15%	100.00	100.00	8.00	8.00	25.81	25.40	8.00	8.00	99.81	99.81	25.81	24.83	99.03	99.03	37.80	32.74
	20%	100.00	40.32	8.00	8.00	34.42	33.87	8.00	8.00	99.74	99.74	34.42	33.11	98.71	98.71	50.40	43.65
	25%	100.00	50.41	8.00	8.00	43.02	42.34	8.00	8.00	99.68	99.68	43.02	41.39	98.38	98.38	63.01	54.57
	30%	100.00	60.49	8.02	8.00	51.62	50.80	8.02	8.02	99.61	96.14	51.62	49.67	98.06	98.06	75.61	65.48
	35%	100.00	70.57	9.36	8.00	60.23	58.83	9.36	9.36	99.55	112.16	60.23	57.94	97.74	97.74	88.21	76.39
	40%	100.00	80.65	10.69	8.00	68.83	67.44	10.69	10.69	99.48	128.18	68.83	66.22	104.62	104.62	100.81	87.31
	45%	100.00	90.73	12.03	8.00	77.44	76.20	12.03	12.03	99.42	144.21	77.44	74.50	117.70	117.70	113.41	98.22
	50%	100.00	100.81	13.37	8.00	86.04	84.67	13.37	13.37	99.36	160.23	86.04	82.78	130.78	130.78	126.01	109.13
	2002	10%	100.00	100.00	8.00	8.00	16.93	16.93	8.00	8.00	99.87	99.87	16.93	12.89	99.35	99.35	23.74
15%		100.00	100.00	8.00	8.00	25.40	25.40	8.00	8.00	99.81	99.81	25.40	19.33	99.02	99.02	35.61	29.83
20%		100.00	100.00	8.00	8.00	33.87	33.87	8.00	8.00	99.74	99.74	33.87	25.77	98.70	98.70	47.49	39.77
25%		100.00	100.00	8.00	8.00	42.34	42.34	8.00	8.00	99.68	99.68	42.34	32.22	98.37	98.37	59.36	49.71
30%		99.99	70.56	8.05	8.00	50.80	50.80	8.03	8.03	99.62	96.12	50.80	38.66	98.05	98.05	71.23	59.65
35%		99.99	82.32	9.39	8.00	59.27	59.27	9.37	9.37	99.55	112.14	59.27	45.10	97.72	97.72	83.10	69.59
40%		99.99	94.08	10.73	8.00	67.74	67.74	10.70	10.70	99.49	128.16	67.74	51.54	97.40	97.40	94.97	79.53
45%		99.99	105.84	12.08	8.00	76.20	76.20	12.04	12.04	99.42	144.18	76.20	57.99	111.86	111.86	106.84	89.48
50%		99.99	117.60	13.42	8.00	84.67	84.67	13.38	13.38	99.36	160.20	84.67	64.43	124.29	124.29	118.71	99.42

Tabela 3.2: Capital Econômico (em termos percentuais) calculado por meio de dados de credores classificados em 4 níveis: A, BBB, BB e B. Esta análise foi feita também com dados disponíveis em dois anos distintos, 1998 e 2002.

4 Modelos de Previsão de Falências e Aprendizagem de Máquinas

Instituições financeiras, gestores de fundos, financiadores, governos e diversos intervenientes no mercado financeiro procuram desenvolver modelos para determinar de forma eficiente a probabilidade de inadimplência de contrapartes. Embora os eventos sigam um padrão de comportamento estocástico, informações sobre o mercado de capitais pode contribuir para o desenvolvimento de modelos de previsão de falência. Por exemplo, [Altman \(1968\)](#), em seu artigo seminal, aplica técnicas estatísticas multivariadas, em particular a análise discriminante, para classificar empresas solventes e insolventes usando dados das demonstrações financeiras.

É importante ressaltar que o risco de crédito surge não só devido a eventos de falência, mas também a partir do rebaixamento dos *ratings* de dívida de ativos de crédito relacionado. Embora os modelos padrão têm sido estudados há décadas, a crise financeira 2007/2008 tornou o gerenciamento de risco de crédito uma prioridade. Embora seja uma grande preocupação, [Wang et al. \(2014\)](#) sugerem que não existe uma teoria madura ou definitiva do fracasso empresarial. Portanto, a falta de um quadro teórico para examinar falência justifica estudos exploratórios para identificar características discriminantes e modelos preditivos para risco de crédito com base em processos de tentativa e erro ([LI; SUN, 2009](#); [WANG et al., 2014](#); [ZHOU et al., 2014](#)).

Pesquisadores e profissionais têm procurado melhorar os modelos de previsão de falência usando várias abordagens quantitativas. Por exemplo, [Ohlson \(1980\)](#) foi um dos primeiros pesquisadores a aplicar a análise de regressão logística em estimativas padrão. Em contraste com o modelo de [Altman \(1968\)](#), o que gera uma pontuação para classificar uma observação entre bons e maus pagadores, de Ohlson modelo [Ohlson \(1980\)](#) fornece a probabilidade de inadimplência.

Dada a relativa facilidade de análise discriminante e regressão logística, vários estudos subsequentes têm procurado realizar testes semelhantes (por exemplo, [Hillegeist et al. \(2004\)](#), [Upneja e Dalbor \(2001\)](#), [Griffin e Lemmon \(2002\)](#) e [Chen et al. \(2010\)](#)). No entanto, [Begley et al. \(1996\)](#) identificaram que os modelos populares [Altman \(1968\)](#) e [Ohlson \(1980\)](#) perderam precisão ao longo do tempo, o que sugere a necessidade de novas melhorias na modelagem do risco de incumprimento.

Com o avanço da tecnologia da informação, acadêmicos e profissionais estão explorando modelos de inteligência e de aprendizado de máquina artificiais para avaliar o risco de crédito. Como a análise de risco de crédito é semelhante a problemas de reconhecimento de padrões, algoritmos podem ser implementados para classificar qualidade

de crédito de contrapartes, avançando os modelos tradicionais com base em técnicas de estatística multivariada mais simples, como análise discriminante e regressão logística.

Nesse contexto, outros métodos têm sido desenvolvidos, trazendo novas alternativas para a análise do risco de crédito. Entre eles, destacam-se a máquina de métodos de aprendizagem. Máquinas de vetores de suporte, de Cortes e Vapnik (1995), também conhecido como *Support Vector Machines* (SVM), por exemplo, tem características semelhantes à análise discriminante, mas não estão sujeitos a uma série de premissas, e por isso são menos restritivas. Também foram propostos outros métodos de aprendizado de máquina, com uma ampla aplicabilidade em modelos de previsão, incluindo os modelos de *default*, como *boosting*, *bagging* e *random forest*. Além disso, as redes neurais artificiais (ANN) foram aplicadas em muitos outros contextos, como física, biologia, entre outros.

A incorporação de tais algoritmos de aprendizado de máquina mostra-se uma evolução promissora no desempenho dos modelos de classificação. Por exemplo, utilizando conjuntos de dados financeiros australianos, alemães, japoneses, Nanni e Lumini (2009) verificaram que as técnicas de aprendizado de máquina, por exemplo, métodos de *ensemble*, levam a melhor classificação do que os métodos autônomos.

Embora muitos estudos tenham analisado a solvência da empresa utilizando técnicas computacionais modernas, Wang et al. (2014) concluíram que não houve resultados definitivos sobre o melhor método, uma vez que o desempenho do modelo dependia das características específicas do problema de classificação, bem como a estrutura de dados (GUZMÁN; VOSE, 2013). Além disso, Wang et al. (2011), utilizando métodos de *ensemble* (*boosting*, *bagging* e *stacking*), juntamente com métodos mais comuns (regressão logística, árvores de decisão, ANN e SVM) descobriram que *bagging* superou *boosting* para todos os bancos de dados de crédito por eles analisados.

Essa pesquisa analisa o desempenho de diferentes técnicas de classificação, considerando vários algoritmos de aprendizado de máquina e o problema prático da previsão de falência. Para o estudo comparativo, foi utilizado um conjunto de treinamento de empresas falidas e não falidas de 1985 a 2005 e um conjunto de validação de 2006 a 2013, obtendo a matriz de confusão. Indicadores de precisão global e a área sob a curva (AUC) característica de operação do receptor (*ROC*) foi empregada como critério comparativo de desempenho para os modelos em questão.

Para perceber a importância das variáveis utilizadas neste estudo, uma comparação destes resultados com os mesmos modelos que utilizam somente o *Z-Score* das variáveis foi realizada, considerando as medidas de erro do tipo I e II. Como consequência, todos os modelos mostraram menor precisão quando o número de variáveis é reduzido.

Na Seção 4.1, discute-se brevemente os principais modelos de aprendizado de máquina. Na Seção 4.2, apresenta-se o método e os dados. Os resultados da classificação dos diferentes modelos são defendidos na Seção 4.3, e a Seção 4.4 expõe os comentários

finais e as implicações do estudo, incluindo vantagens e desvantagens de cada modelo, bem como sugestões para futuras pesquisas.

4.1 Fundamentação Teórica

Os métodos de aprendizagem de máquinas são considerados um dos avanços mais recentes e importantes na matemática aplicada, com implicações para problemas de classificação [Tian et al. \(2012\)](#). As técnicas de aprendizado de máquina avaliam os padrões de observações com a mesma classificação e identificam características que diferenciam as observações de diferentes grupos.

Estudos de aprendizado de máquina são encontrados em meio a um vasto leque de investigação, incluindo a medicina ([NOBLE, 2006](#); [SUBASI; GURSOY, 2010](#)), engenharia ([OSKOEI; HU, 2008](#)), a computação ([OSUNA et al., 1997](#)), entre outros. Nesse estudo, os mecanismos de aprendizagem de máquina são treinados para classificar falência empresas de empresas não falidas, com base em características das empresas, como, por exemplo, medidas de lucratividade, liquidez, endividamento, tamanho e crescimento.

A proposta desta pesquisa é comparar as aplicações dos métodos de SVM, *boosting*, *bagging* e *random forest* com ANN, regressão logística e análise discriminante. Esta seção fornece uma breve revisão de cada um destes mecanismos, considerando os objetivos específicos, modelagem matemática, e algoritmos de aprendizagem.

A solução do problema de análise de crédito, mais especificamente, da aplicação de pontuação, envolve a identificação da categoria (por exemplo, bom ou mau mutuário, empresa falida ou não-falida) a que cada observação pertence. O procedimento baseia-se na definição de variáveis discriminantes potenciais e a identificação de pesos ou coeficientes, que podem ser utilizadas em funções matemáticas que poderiam separar os grupos.

4.1.1 *Support Vector Machines*

Seguindo [Noble \(2006\)](#), o modelo de otimização SVM empregado aqui é baseado na transformação de uma função matemática por outra função chamada de *kernel*, no qual tem-se a intenção de maximizar a distância entre a maioria das observações semelhantes que são previamente conhecidas por terem classificações opostas.

Um critério bastante peculiar envolve a questão dos grupos serem completamente separáveis, pois isso permitiria que o SVM construa um modelo com precisão de 100%. Em finanças isto é praticamente impossível, porque as variáveis econômicas são influenciadas por dados empíricos e muitas vezes são tendenciosos. Para problemas de classificação de grupos separáveis parcialmente, o método SVM permite a inclusão de uma

margem de erro.

Em geral, o número de variáveis não é uma restrição do problema de otimização (TRUSTORFF et al., 2010). O algoritmo associado ao modelo quantitativo estabelece um mecanismo de classificação, calibra parâmetros usando um conjunto de treinamento, ou seja, o algoritmo aprende com os dados de treinamento. O sistema de classificação resultante pode então ser aplicado para prever o agrupamento ou classificação de novas observações. Normalmente, conjunto de validação também é avaliado para comparar a classificação dada pelo modelo com o grupo atual ao qual a observação pertence. Os conjuntos de validação e de formação são independentes, ou seja, não há observações comuns entre tais grupos.

A partir de (LI; SUN, 2009), o problema de otimização podem ser resumidos como:

$$\text{Mimize} \quad \frac{1}{2}w^T w + C \sum_{i=1}^M \xi_i, \quad (4.1)$$

sujeito a

$$y_i[w^T \phi(x_i) + b] \geq 1 - \xi_i, \quad (4.2)$$

tal que $i = 1, 2, \dots, M$, $\xi_i \geq 0$ são as margens de erro relacionadas a um custo de classificação C , y_i são as classificações no conjunto de treinamento, e $\phi(x)$ transforma o espaço \mathbb{R}^M . Uma vantagem da técnica é que $\phi(x)$ não necessita ser conhecida, uma vez que uma função *kernel* ($K(x) = K(x_i, x_j)$) é aplicada de tal forma que $K(x) = \phi(x_i)^T \phi(x_j)$.

A função *kernel* é pré-determinada no algoritmo e também consegue encontrar uma solução para o problema de otimização (Equações 4.1 e 4.2). As funções *kernel* mais aplicadas são

$$K(x_i, x_j) = \langle x_i, x_j \rangle, \quad (4.3)$$

e

$$K(x_i, x_j) = e^{(-\gamma \|x_i - x_j\|^2)}. \quad (4.4)$$

onde γ é uma constante positiva. A Equação (4.3) é chamada de *kernel* linear e (4.4) é a função de base radial (RBF). O *kernel* linear não fornece grande previsibilidade em conjuntos de dados não separáveis, devido a complexidade de analisar as taxas empíricas, mas os resultados são facilmente interpretados pelos próprios usuários. Por outro lado, o *kernel* RBF também é difícil de analisar, ou mesmo discutir, no entanto ele fornece previsões superiores em casos não separáveis.

Mais detalhes sobre o método SVM pode ser encontrado em Cortes e Vapnik (1995), Min e Lee (2005), Yu et al. (2010).

4.1.2 *Bagging*

Também conhecido como *bootstrap aggregating*, *bagging* é uma técnica que envolve classificadores independentes, usando partes dos dados e, em seguida, combina-os por meio do modelo de média, que fornece os resultados mais eficientes no que diz respeito a uma coleção.

Bagging cria novos subconjuntos aleatórios de dados por amostragem de um determinado conjunto de dados. Isso gera estimativas de intervalo de confiança. Depois, *bagging* cria um número fixo de aprendizes independentes, que fazem seus próprios conjuntos de dados de treinamento, e permite substituições. O conceito por trás da técnica de *bagging* é reduzir sobreajustamento de uma classe dentro do modelo. Ao invés de usar a coleção e verificar se o modelo é sobreajustado, o conjunto de treinamento é re combinado para produzir melhores classificadores.

O algoritmo de *bagging* aplicado neste trabalho, com base em Breiman (1996), segue os seguintes passos:

1. Um conjunto de inicialização aleatória, t , é selecionado entre o conjunto de dados-pai.
2. Classificadores C_t são configuradas no conjunto de dados a partir do passo 1.
3. As etapas 1, 2 são repetidos por $t = 1, \dots, T$, em que T é o total de iterações definido pelo executor.
4. Cada classificador determina um voto,

$$C(x) = T^{-1} \sum_{t=1}^T C_t(x) \quad (4.5)$$

em que x comporta os dados de cada elemento do conjunto de treinamento.

A classe com a maior votação é escolhida como a classificação para cada elemento do conjunto de dados.

4.1.3 *Boosting*

A hipótese da técnica de *boosting* Begley et al. (1996) consiste no uso repetido de uma regra de predição base (ou função) em diferentes amostras do conjunto inicial. *Boosting* constrói outros esquemas de classificação, como *bagging*, e atribui um peso para cada conjunto de treinamento, que é então incorporada ao modelo, e então os dados são redistribuídos. O método de *boosting* pode ser usado pelo classificador base para encontrar um modelo que melhor classifica o conjunto, tal como definido por uma baixa taxa de erro para o conjunto de treino.

Um algoritmo derivado, *AdaBoost* (*boost* adaptativo) tem sido utilizado com êxito para a previsão de classificação (e.g., [KIM; UPNEJA, 2014](#)). *AdaBoost* inicializa os pesos para todos as m amostras valendo $1/m$. Assim, a primeira geração tem ponderação uniforme. Depois de extrair o conjunto de treinamento x_i , de X , um classificador y_i é treinado em x_i . A taxa de erro é calculada considerando o número de variáveis do conjunto de treino. O novo peso para cada variável é a eficácia do classificador, y_i . Se a taxa de erro é superior a suposição aleatória, o conjunto de teste é descartado, e outro conjunto é gerado com os pesos iniciais (inicialmente $1/m$). Se a taxa de erro é satisfatória, os pesos são atualizados de acordo com a importância do classificador. O algoritmo empregado neste estudo segue [Heo e Yang \(2014\)](#) aplicando a formulação a seguir.

1. Cria-se uma distribuição inicial dos pesos, $w_1(i) = 1/m$, de modo que $i = 1, 2, \dots, m$; e w_t é a ponderação iterativa ($t = 1, \dots, T$),

$$w_{t+1}(i) = \frac{w_t(i)e^{\alpha_t(2I(y_i \neq h_t) - 1)}}{w_t(i)e^{\alpha_t I(y_i \neq h_t)}}, \quad (4.6)$$

tal que $h_t = \operatorname{argmax}|0.5 - \xi_t|$ é a media de erro, $\xi_t = \sum_{t=1}^m w^t(t)I(y_t \neq h_t(x_t))$, e $I = 1$ quando a medida for precisamente calculada ou 0, caso contrário.

2. Em cada novo ciclo, $\alpha_t = \frac{1}{2} \ln\left(\frac{1-\xi_t}{\xi_t}\right)$ é recalculado.
3. A rotina completa termina quando $|0.5 - \xi_t| \neq \delta$, tal que δ é uma constante pré-definida.
4. $Y(x)$ é calculada quando a técnica *boost* finaliza seus procedimentos.

$$Y(x) = \operatorname{sign} \sum_{t=1}^T \alpha_t h_t(x) \quad (4.7)$$

4.1.4 *Random Forest*

A técnica de *random forest* é baseada em modelos de árvore de decisão, também conhecidos como árvores de classificação e regressão generalizadas (CART). O modelo tem precisão semelhante ao *AdaBoost* e, dependendo do conjunto, pode fornecer melhores resultados do que aumentar ([KRUPPA et al., 2013](#); [BREIMAN, 2001](#)). É particularmente robusto e permite a presença de *outliers* e ruídos no conjunto de treinamento. Finalmente, *random forest* também fornece a importância de cada variável nos resultados da classificação, e assim fornece não só a classificação de observações, mas também informações sobre determinantes da separação entre os grupos.

Random Forest segue uma abordagem semelhante à de *bagging*, na medida em que gera repetidamente funções de classificação baseadas em sub-conjuntos. No entanto, esse método seleciona aleatoriamente um subconjunto de características de cada nó da

árvore, evitando correlação nos conjuntos de *bootstrap*. A floresta é construída por vários subconjuntos que geram o mesmo número de árvores de classificação. A classe preferida é definida por maioria de votos, fornecendo previsões mais precisas e, mais importante, evitando o excesso de ajuste dos dados (BREIMAN, 2001).

O algoritmo de *random forest* nesta pesquisa é aplicado como se segue:

1. Criar subconjuntos aleatórios do conjunto dos pais, compostos por um número arbitrário de observações e características diferentes.
2. Cada subconjunto do passo 1 produz uma árvore de decisão e todos os elementos do conjunto tem um rótulo (corretos ou não).
3. Para cada elemento a floresta tem um grande número de votos. A classe com o número máximo de votos é escolhida como a classificação preferida do elemento.

Uma discussão mais detalhada sobre as florestas aleatórias, incluindo uma descrição matemática mais rigorosa, é apresentada em Breiman (2001), Booth et al. (2014) e Calderoni et al. (2015).

4.1.5 Redes Neurais Artificiais

ANN é uma das técnicas de inteligência artificial mais populares e inspiraram outros modelos de classificação computacionais. Esse método faz uma analogia com o processamento neural humano. Muitos relacionamentos não-lineares podem ser analisados com métodos de ANN. No entanto, mais recentemente, tem sido demonstrado que os métodos de aprendizagem de máquina tendem a proporcionar melhores resultados de classificação ((FREUND; SCHAPIRE, 1997; KIM; KANG, 2010); e (KRUPPA et al., 2013)).

Zhao et al. (2014) utilizaram dados de crédito alemães para construir um modelo de pontuação de crédito usando ANN. Os autores acreditam que ANN com a propagação de volta prediz a pontuação de crédito com boa precisão. Eles descobriram eficiência de 87 % da classificação e concluíram que seu modelo foi um pouco melhor do que os modelos tradicionais.

O algoritmo ANN que se usa nesta pesquisa é idêntico aquele aplicado em Wang et al. (2011) e Zhao et al. (2014). O modelo é uma estrutura (rede), criada em camadas, com ligações (arcos) entre os nós (neurônios). As variáveis de entrada determinam a primeira camada do sistema de modelação e a camada final proporciona a variável de saída (dependente). Aqui, a variável dependente é a classificação de empresas falidas, com dados de um ano antes da data do anúncio oficial, e não falidas. A Probabilidade de *default* também é um resultado importante e para obtê-la, classificou-se as firmas em dois níveis por meio de um número real entre 0 (falência) e 1 (não-falência).

No entanto, três problemas foram identificados com a técnica de ANN [Zhao et al. \(2014\)](#): (i) desempenho em dados desbalanceados é fraco, porque tende a classificar mais observações em classes com mais dados e, portanto, o conjunto de teste perde capacidade de prever adequadamente. (ii) A precisão do modelo aumenta com o tamanho do conjunto de treino, mas a validação é insuficiente para proporcionar uma taxa de erro satisfatória. (iii) A dificuldade de selecionar as camadas ocultas, considerando a questão do tempo (necessário por mais camadas) de computação contra a melhor previsibilidade. Adotou-se neste estudo um esquema semelhante a [Zhao et al. \(2014\)](#) para abordar tais questões e aplicar ANN.

4.1.6 Análise Discriminante e Regressão Logística

Análise Discriminante Multivariada (MDA) foi um avanço na avaliação de risco de crédito, quando [Altman \(1968\)](#) apresentou um estudo de falência em empresas de manufatura, obtendo resultados de classificação tão relevantes que são estudados até hoje. O método baseia-se na minimização da variância de observações do mesmo grupo e na maximização da distância entre as observações de diferentes grupos. O método produz uma pontuação, e uma observação é classificada a um grupo, dependendo da pontuação em relação a um valor de corte arbitrário.

As hipóteses restritivas de MDA, como exigir variáveis normalmente distribuídas e sensibilidade a *outliers*, fez a abordagem de regressão logística (LR) se tornar o modelo multivariado mais popular na área de técnicas de classificação e, posteriormente, para a modelagem de risco de crédito. Não só os pressupostos são menos restritivos, como também a técnica fornece dados de saída no intervalo $[0, 1]$, que pode ser interpretados como a probabilidade de uma dada observação ser um membro de um grupo (ou classe) específico(a).

No entanto, vários estudos ([KRUPPA et al., 2013](#); [TRUSTORFF et al., 2010](#)) demonstraram que tais métodos multivariados tradicionais não são tão eficientes ou precisos como técnicas de aprendizado de máquina mais recentes para a classificação de risco de crédito.

4.2 Dados e Método

Foram coletados dados financeiros das empresas americanas e canadenses entre 1985 e 2013, usando como fonte de dados das firmas a base de dados da *Compustat*. Tais informações não incluem dados de insolvência e, dessa forma, esses dados foram coletados a partir da base de dados do *Credit & Debit Markets Research Program* do *Salomon Center*, em Nova York.

Um subconjunto entre 1985 e 2005 foi extraído para fornecer o conjunto de treinamento. O conjunto de treinamento incluiu informações de 449 empresas que entraram em processo de falência neste período e o mesmo número de empresas não-falência. As empresas insolventes no conjunto de treinamento incluem todas as empresas do banco de dados que entraram em falência durante este período e tiveram dados financeiros disponíveis três anos antes da apresentação. As empresas solventes foram escolhidas aleatoriamente, incluindo-se apenas empresas que não foram à falência durante todo o período (1985 a 2005) e que os dados financeiros também estiveram à disposição, pelo menos, para três anos consecutivos. Optou-se por selecionar o mesmo número de empresas solventes e insolventes, seguindo [Altman \(1968\)](#), que também considera um conjunto balanceado em seu trabalho. As Figuras 4.1 e 4.2 mostram o número de empresas solventes e insolventes, respectivamente, em cada ano e também a indústria, separados por cor, conforme a legenda apresentada.

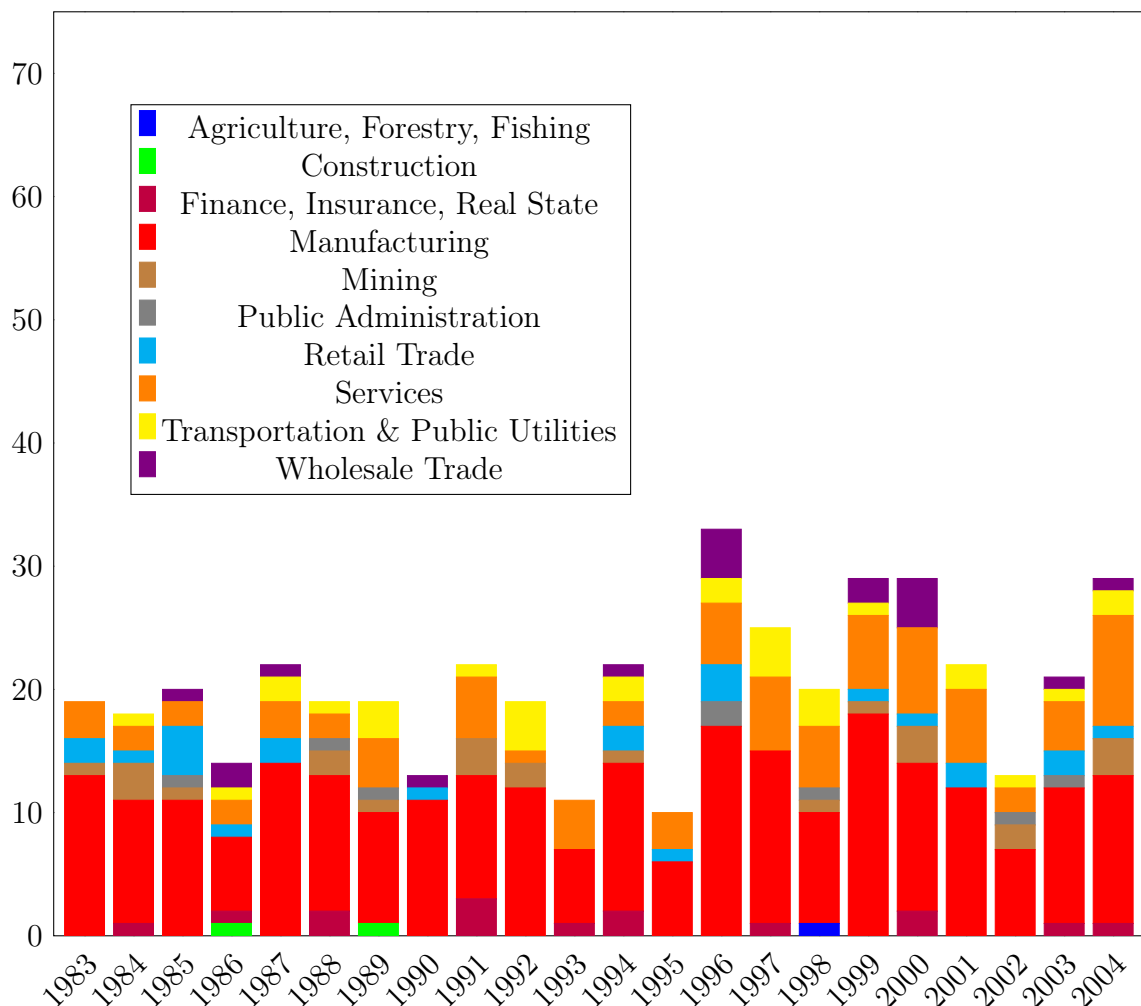


Figura 4.1: Empresas solventes presentes na amostra de treinamento, apresentadas por ano e indústria. Fonte: preparado pelo autor com dados extraídos do *Salomon Center – NYU* e da base de dados *Compustat*.

As variáveis preditivas foram escolhidas com base em dois estudos importantes: o papel seminal de [Altman \(1968\)](#), e uma avaliação de desempenho organizacional

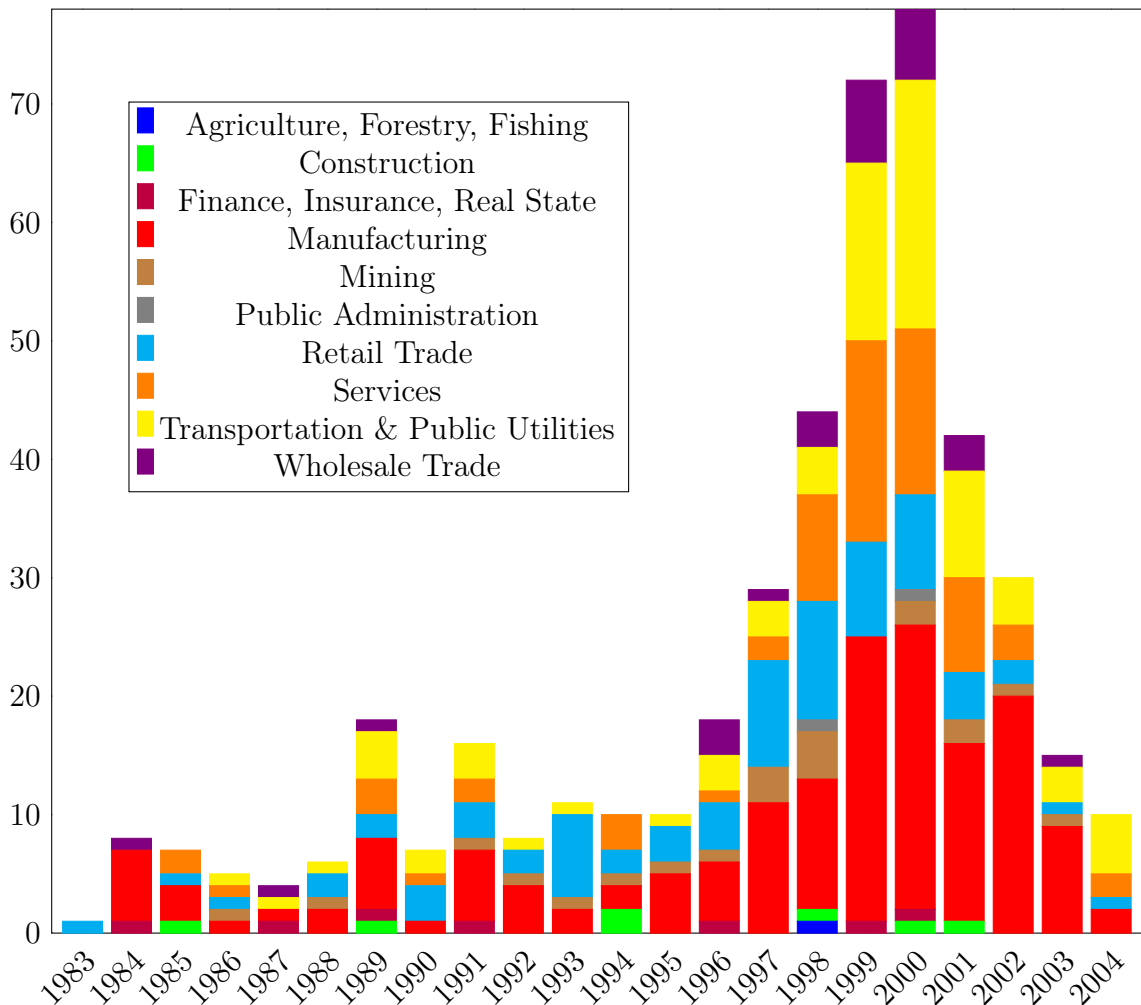


Figura 4.2: Empresas falidas por ano e indústria, de um total de 449 na amostra de treinamento. Os dados cobrem um período de pouco mais de 20 anos e considera dados de falência para uma ano antes do evento. Fonte: preparado pelo autor com dados extraídos do *Salomon Center – NYU* e da base de dados *Compustat*.

feita por [Carton e Hofer \(2006\)](#). As cinco variáveis que formam as dimensões financeiras relevantes de [Altman \(1968\)](#) são: liquidez ($X1$), rentabilidade ($X2$), produtividade ($X3$), a alavancagem ($X4$), o volume de negócios e ativos ($X5$). Para analisar o impacto potencial de outras dimensões na previsão de falências, também incluímos indicadores com maior influência nos modelos de desempenho financeiro no curto prazo, conforme [Carton e Hofer \(2006\)](#): crescimento dos ativos (GA), o crescimento em vendas (GS), o crescimento da o número de empregados (GE), margem operacional (OM), mudança no retorno sobre o patrimônio (CROE), e mudança na taxa *Price-to-Book* (CPB). Os dados foram reorganizados como variáveis, descritas na Tabela 4.1.

O conjunto de validação contém 133 eventos de falência e 13.300 empresas consideradas solventes a partir de 2006 (o que não está presente na período de treinamento) e, também escolhidos aleatoriamente. No caso de empresas falidas, foram incluídas todas as empresas com dados disponíveis no banco de dados, pelo menos, um ano antes do depósito. Se o evento ocorreu durante o primeiro semestre, os dados foram coletados a

Variável	Fórmula
X1	$\frac{\text{Capital de Giro Líquido}}{\text{Ativos Totais}}$
X2	$\frac{\text{Lucros Retidos}}{\text{Ativos Totais}}$
X3	$\frac{\text{Lucros antes de Juros e Impostos}}{\text{Ativos Totais}}$
X4	$\frac{\text{Valor de Mercado das ações} * \text{número de ações}}{\text{Total de dívida}}$
X5	$\frac{\text{Vendas}}{\text{Ativos Totais}}$
OM	$\frac{\text{Lucros antes de Juros e Impostos}}{\text{Vendas}}$
GA	$\frac{\text{Ativos Totais}_t - \text{Ativos Totais}_{t-1}}{\text{Ativos Totais}_{t-1}}$
GS	$\frac{\text{Vendas}_t - \text{Vendas}_{t-1}}{\text{Vendas}_{t-1}}$
GE	$\frac{\text{Número de Empregados}_t - \text{Número de Empregados}_{t-1}}{\text{Número de Empregados}_{t-1}}$
CROE	$\text{ROE}_t - \text{ROE}_{t-1} \text{ em que } \text{ROE} = \frac{\text{Lucro Líquido}}{\text{Patrimônio Líquido}}$
CPB	$\text{Price-to-Book}_t - \text{Price-to-Book}_{t-1} \text{ tal que } P/B = \frac{\text{Valor de Mercado da ação}}{\text{Valor contábil da ação}}$

Tabela 4.1: Variáveis preditoras do modelo de previsão de falência um ano antes do evento em si. Se a data de anúncio da falência ocorrer em até seis meses após o fechamento do ano fiscal, os dados coletados são apurados um ano antes. Algumas medidas requerem registros ao longo do tempo e, dessa forma, essas variáveis requerem dados de até três anos anteriores.

partir do segundo ano fiscal anterior. Em outra classe, todos (não-falência) 13.167 empresas solventes foram selecionados a partir de um ano aleatório dentro deste período para o conjunto de teste.

Em suma, foram aplicadas sete técnicas:

- MDA;
- de regressão logística (*Logit*);
- SVM artigo com dois núcleos: Linear (SVM-Lin) e *Radial Basis Function* (SVM-RBF);

- *Boosting*;
- *Bagging*;
- Redes Neurais Artificiais (ANN); e,
- *Random Forest* (RF).

Implementaram-se os modelos usando o *software* estatístico R ¹, por meio de um computador pessoal *MacBook Air* da *Apple* com sistema operacional OS X Yosemite versão 10.10.1, com processador Intel Core i5 de 1.4GHz, memória RAM de 4GB, 1600MHz DDR3 e placa gráfica Intel HD Graphics 5000 1536 MB.

A curva *ROC* foi calculada para todos os modelos para os conjuntos de treinamento e validação, fornecendo uma análise crítica da evolução da aprendizagem de máquina. A medida de AUC também forneceu um critério de precisão para o conjunto de validação. AUC deve ser superior a 0,5 para o modelo ser aceitável, e quanto mais próximo de 1 for, o modelo terá um melhor poder de previsão.

As taxas de desempenho comumente aplicadas por Wang et al. (2012) e Kim e Upneja (2014) foram calculadas: a *True Positive Rate* (TPR), conhecida por Sensibilidade e a *True Negative Rate* (TNR), ou Especificidade, que são equivalentes a 1– Erro do Tipo I, e 1– Erro do Tipo II, respectivamente. O poder preditivo, ou precisão (ACC), foi calculado a partir do número de classificações precisas, dividido pelo número total de elementos do conjunto de validação. Estes são equivalentes aos propostos por Altman (1968), portanto, é possível comparar diretamente com seus resultados. Em última análise, a qualidade de classificação é determinado pela matriz de resultados, um exemplo é mostrado na Tabela 4.2.

		Previsto	
		Falência	Não-Falência
Situação Real	F	<i>Verdadeiro Positivo</i>	Falso Negativo
	NF	Falso Positivo	Verdadeiro Negativo

Tabela 4.2: Forma da matriz de resultados da classificação, ilustrando a posição com que se apresenta os dados de saída em uma tabela. Os resultados deste trabalho são mostrados nesse padrão.

Assim, as variáveis são dadas por:

$$\text{Sensibilidade} = \text{TPR} = 1 - \text{Erro do Tipo I} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (4.8)$$

$$\text{Especificidade} = \text{TNR} = 1 - \text{Erro do Tipo II} = \frac{\text{TN}}{\text{TN} + \text{FP}} \quad (4.9)$$

¹R é um conjunto de pacotes estatísticos de fonte aberta com todos os módulos necessários disponíveis que permitem ajustes aos modelos para acomodar os diversos dados e arranjos de parâmetros.

em que TP é chamado de verdadeiro positivo, ou seja, as empresas não-falidas classificadas corretamente e TN é verdadeiro negativo ou a quantidade de empresas falidas classificadas corretamente.

A Sensibilidade tem valores próximos a 1 quando o Tipo I de erro é baixo, e especificidade está perto de 1 quando o erro Tipo II é baixa. No caso de estudos de previsão de falência, há uma preferência para maior sensibilidade, porque isso se traduz em perdas para os credores, enquanto a especificidade é o limite para o ganho. No entanto, uma discrepância na especificidade pode trazer problemas de restrição exagerada de crédito, limitando exageradamente o lucro dos credores.

A Figura 4.3 demonstra a nossa metodologia.

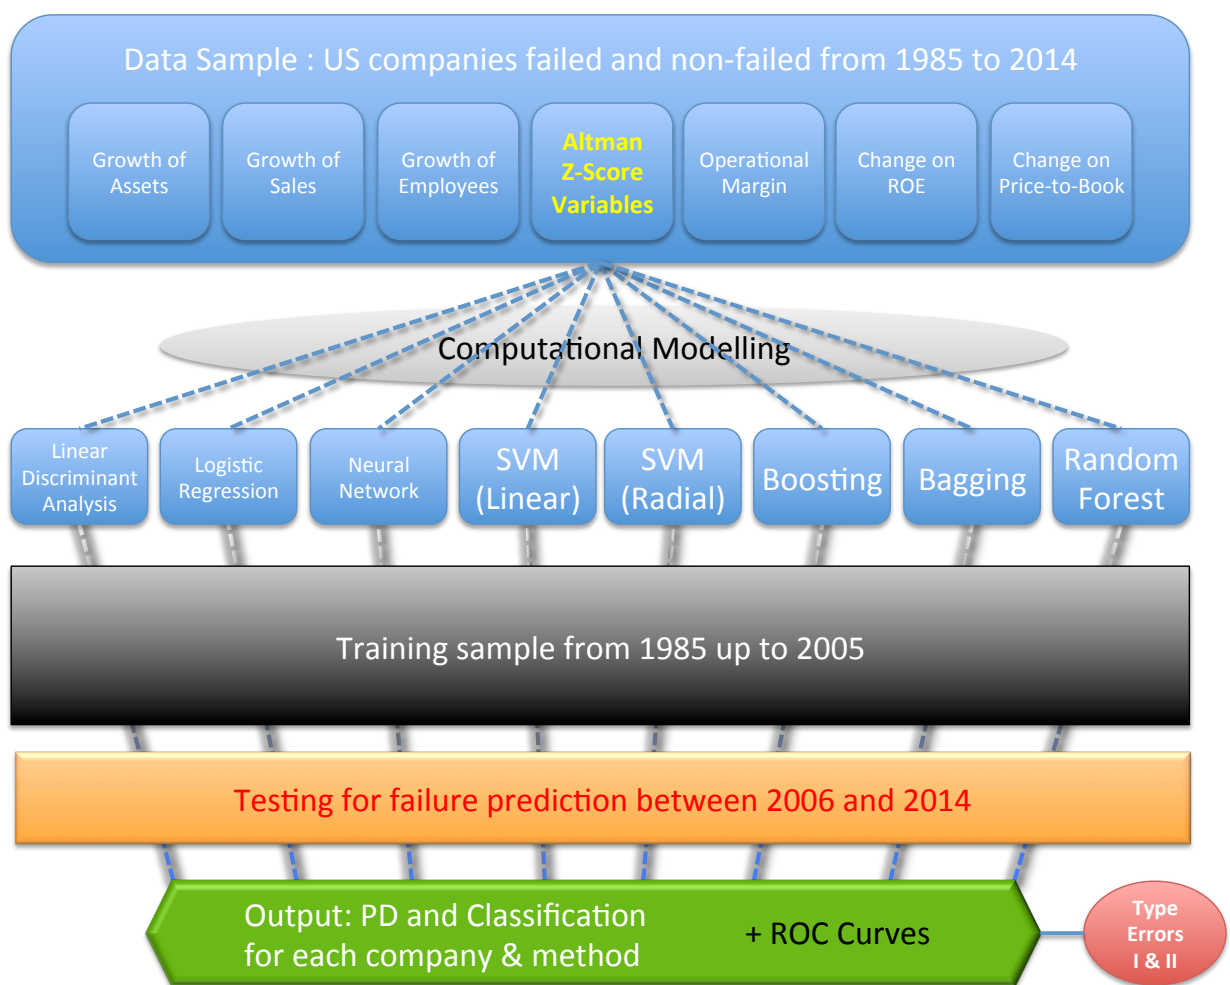


Figura 4.3: *Graphical Abstract* – 11 variáveis foram selecionadas, incluindo as variáveis do Z-Score de Altman e medidas de crescimento, variação, e margem operacional, como sugerido por Carton e Hofer (2006). Modelos de aprendizagem de máquina usados: máquinas de vetores de suporte usando *kernels* de base lineares e radiais, *boosting*, *bagging* e *random forest*. Os modelos tradicionais utilizados: redes neurais artificiais, regressão logística e análise discriminante multivariada. Os resultados são apresentados como matrizes de confusão e curvas *ROC*.

4.3 Resultados

Os resultados para as técnicas tradicionais, MDA, Logit, e ANN são mostrados nas Tabelas 4.3, 4.4 e 4.5, respectivamente. Empresas falidas são apontadas como F, e NF para as empresas não falidas, seguindo a estrutura da Tabela 4.2 e separadas em saídas dos conjuntos de treinamento e de validação. As Tabelas 4.6 a 4.10 mostram os resultados para os modelos de SVM-Lin, SVM-RBF, BST, BAG, e RF, respectivamente.

		Training set		Validação	
		Falência	Non-Falência	Falência	Non-Falência
Real	F	361	88	86	47
	NF	228	221	6313	6854

Tabela 4.3: Matriz de confusão para o modelo de MDA.

		Training sample		Validation sample	
		Falência	Non-Falência	Falência	Non-Falência
Real	F	414	35	118	15
	NF	120	329	3139	10028

Tabela 4.4: Matriz de confusão para o modelo de *Logit*.

		Treinamento		Validação	
		Falência	Non-Falência	Falência	Non-Falência
Real	F	431	18	124	9
	NF	118	331	3585	9582

Tabela 4.5: Matriz de confusão para o modelo de Redes Neurais.

		Treinamento		Validação	
		Falência	Non-Falência	Falência	Non-Falência
Real	F	419	30	123	10
	NF	143	306	3778	9389

Tabela 4.6: Matriz de confusão para o modelo de SVM com *kernel* linear.

		Treinamento		Validação	
		Falência	Não-Falência	Falência	Não-Falência
Real	F	421	28	105	28
	NF	73	376	2662	10505

Tabela 4.7: Matriz de confusão para o modelo de SVM com *kernel* de função de base radial (SVM-RBF).

		Treinamento		Validação	
		Falência	Não-Falência	Falência	Não-Falência
Real	F	434	15	108	25
	NF	19	430	1750	11417

Tabela 4.8: Matriz de confusão para o modelo de *Boosting*.

		Treinamento		Validação	
		Falência	Não-Falência	Falência	Não-Falência
Real	F	448	1	110	23
	NF	2	447	1883	11284

Tabela 4.9: Matriz de confusão para o modelo de *Bagging*.

		Treinamento		Validação	
		Falência	Não-Falência	Falência	Não-Falência
Real	F	449	0	111	22
	NF	0	449	1699	11468

Tabela 4.10: Matriz de Confusão para o modelo de *Random Forest*

Model	Erro do Tipo I (%)	Erro do Tipo II (%)	AUC (%)	ACC (%)
SVM-Linear	7,52	28,69	67,2	71,52
SVM-RBF	21,05	20,22	85,17	79,77
Boosting	18,8	13,29	92,97	86,65
Bagging	17,29	14,3	92,48	85,67
Random Forest	16,54	12,9	92,92	87,06
Neural Networks	6,77	27,23	90,08	72,98
Logit	11,28	23,84	90,1	76,29
MDA	35,34	47,95	63,68	52,18

Tabela 4.11: Resultado em termos percentuais de todos os modelos aplicados às 13.300 empresas. O Erro do Tipo I representa a parte de empresas falidas que foram previstas como não-falidas, enquanto o Erro do Tipo II é o total de empresas não falidas que foram preditas como falidas. AUC é a área sob a curva *ROC* e ACC é a precisão total estimada.

As técnicas BAG (Tabela 4.9) e RF (Tabela 4.10) mostram alta precisão na fase de treinamento. Este resultado era esperado, uma vez que ambos usam árvores de decisão, o que pode causar sobreajuste do modelo no conjunto de treinamento. No entanto, isso não significa que eles são bons modelos, como é evidente com os resultados significativamente piores nos conjuntos de validação.

A Tabela 4.11 mostra as várias métricas (AUC, ACC, Erros do Tipo I e II) discutidos acima, quando os modelos foram aplicados ao conjunto de teste.

É evidente que os modelos de aprendizagem de máquinas superam modelos

tradicionais medidos no conjunto de validação, exceto SVM-Lin.

A estrutura linear aplicada para separar as duas classes (B e NB) é a razão para esse fraco desempenho, uma vez que o MDA, que utiliza um processo semelhante linear mostra uma problema parecido. Assim, as técnicas não lineares são necessárias quando mais variáveis são utilizadas para prever a falência. Enquanto o modelo de ANN apresentaram menor erro do tipo I (6,8 %), seguido pelo SVM-Lin (7,5 %), seu erro tipo II é consideravelmente mais elevado em comparação com outros modelos de aprendizagem de máquina, ou seja, ANN (27,2 %), SVM-lin (28,7 %) em oposição a *Boosting* (13,3 %), *Bagging* (14,3 %) e *Random Forest* (12,9 %).

Em particular, *Boosting* fornece a taxa AUC mais precisa (92,9 %), mas RF retorna o menor Erro do tipo II (12,9 %) e também a melhor taxa de precisão total (87,1 %). Todos os erros e taxas de predição do modelo de aprendizado de máquina são melhores do que o modelo MDA. Enquanto *Logit* é aceitável para classificar as empresas de falência (11,3 % de erro tipo II), o mesmo apresenta má classificação de empresas solventes (23,8 %).

Bagging mostra um desempenho razoável e pode fornecer uma alternativa interessante para os sistemas de aprendizado de máquina mais intensos computacionalmente. Seu Erro Tipo II foi a segunda melhor taxa entre os oito modelos testados (1,4 % acima de RF) e terceiro melhor para AUC e ACC.

A Figura 4.4 mostra a curva *ROC* de todos os modelos em um mesmo plano. Os modelos de aprendizagem de máquinas mostram a superioridade significativa em relação MDA e Logit, exceto SVM-Lin, que é mais semelhante ao MDA, devido aos seus modelos inerentemente lineares, como discutido anteriormente. Embora seja difícil de confirmar uma única técnica mais preferida a partir das curvas, *Bagging*, *Boosting* e *Random Forest* são as candidatas mais promissoras.

Realizou-se vários testes com a seleção de variáveis. Usando apenas o *Z-Score* de Altman (1968), o resultado foi significativamente inferior em termos de poder de previsão. A taxa de sucesso foi comparado ao modelo que usou também as variáveis selecionadas por Carton e Hofer (2006). Nossos resultados mostram a importância usando mais variáveis explicativas, uma vez que a falência pode ser refletida em muitos indicadores diferentes. A Tabela 4.12 mostra os resultados usando apenas as variáveis de Altman (1968).

Neste caso, 14 empresas foram adicionadas à amostra de teste para substituir as empresas que não têm dados suficientes para calcular as taxas de crescimento e, por conseguinte, os dados a partir de apenas um ano antes do evento é suficiente. As 14.553 empresas saudáveis foram redefinidos aleatoriamente, seguindo o método proposto para essa pesquisa.

Há uma diminuição no desempenho de todos os modelos de previsão. Em




Figura 4.4: Curva *ROC* de todos os modelos para prever a falência a partir de 2006 até 2014, com dados coletados na base de dados *Compustat* e *Salomon Center-NYU*. MDA e SVM-Lin mostram menor acurácia, ao mesmo tempo *Boosting*, *Bagging* e *Random Forest* mostram maior poder preditivo.

Modelo	TP	TN	FP	FN	T. Erro T. I	Erro T. II	AUC	ACC
SVM - Linear	141	9203	5350	6	4,08%	36,76%	66,31%	63,56%
SVM - RBF	129	10900	3653	18	12,24%	25,01%	89,54%	75,03%
<i>Boosting</i>	113	12575	1978	34	23,13%	13,59%	91,25%	86,31%
<i>Bagging</i>	116	12452	2101	31	21,09%	14,44%	91,49%	85,5%
<i>RandomForest</i>	112	12536	2017	35	23,81%	13,86%	91,15%	86,04%
Neural Networks	138	10047	4506	9	6,12%	30,96%	91,09%	69,29%
Logit	133	9659	4894	14	9,52%	33,63%	86,18%	66,61%
MDA	119	7254	7299	28	19,05%	50,15%	67,4%	50,16%

Tabela 4.12: As previsões dos modelos aplicados usando as variáveis do modelo popular de [Altman \(1968\)](#). Todos os métodos mostram perda de previsibilidade, sensibilidade e especificidade. Isso mostra a importância de incluir novas variáveis nos modelos.

contrapartida, ANN e SVM-RBF tiveram seus resultados ligeiramente melhorados em termos de AUC, 1 % e 4 %, respectivamente, e também ANN apresentou uma diminuição

no erro do tipo I.

O modelo SVM-Lin, embora diminuindo a precisão, melhorou a sua previsão de empresas falidas, o que também ocorreu com o modelo MDA. Isso se dá muito provavelmente devido à redução das variáveis que permitem um aglomerado mais linear e, como resultado, um melhor desempenho para esses modelos lineares.

Bagging alcançou a maior taxa AUC. No entanto, os erros de Tipo I dos três modelos mais precisos (*Boosting*, *Bagging* e *RF*) foram impactados de forma significativa (cerca de 23 %), enquanto MDA (19 %) e Logit (9,5 %) superaram seus próprios resultados, considerando essa medida. O Erro de tipo II mostra o resultado oposto com uma grande separação ($\approx 20\%$ para Logit e $\approx 36\%$ para MDA), gerando um ACC significativamente melhor.

Seguindo a metodologia descrita aqui, investigou-se também diferentes períodos: treino em períodos pré-crise e validação em períodos de crise (e vice-versa); treino por 5 anos consecutivos e validação um ano mais tarde; e treinamento durante 3 anos consecutivos e validação três anos mais tarde. Os resultados detalhados são omitidos por questões de brevidade. De qualquer forma, eles mostraram sucesso inferior ao modelo descrito aqui. Isso pode ser um indicativo de que tais efeitos e também o tempo podem não ser relevantes para os eventos mais recentes.

No entanto, em todos os testes, sem exceção, as três técnicas de aprendizado de máquina *Boosting*, *Bagging* e *RF* apresentaram os melhores resultados, sendo o último (RF) o melhor método na maioria dos casos.

4.4 Conclusões

A previsão de falências está associada ao risco de crédito, tema que tem estado sob os holofotes devido à recente crise financeira. Modelos de aprendizado de máquina têm sido muito bem sucedidos em suas aplicações em finanças, e muitas obras descrevem sua aplicação a previsão de falências.

Os Modelos de [Ohlson \(1980\)](#) e de [Altman \(1968\)](#) ainda são relevantes, não só devido ao seu poder preditivo, mas também devido às estruturas simples, práticas e coerentes. Poucos estudos podem melhorar seus resultados em termos de precisão das previsões e simplicidade do modelo.

Considerando-se apenas os índices de precisão, nossos resultados mostram que os modelos tradicionais têm capacidade preditiva mais baixa (entre 52 % e 77 %), quando comparados a modelos de aprendizagem de máquina (72 % a 87 %). Isso é corroborado por [Wang et al. \(2012\)](#), [Breiman \(2001\)](#), [Kim e Upneja \(2014\)](#) e [Chen et al. \(2010\)](#). Novos estudos podem adaptar essas técnicas de aprendizado de máquina a outros estudos

de risco de crédito, por exemplo, eventos de inadimplência em geral, não se limitando a falência.

Os modelos computacionais não são perfeitos. SVM-Lin tem dificuldade para lidar com conjuntos de dados não-separáveis e, portanto, produz mais erros de classificação. SVM-RBF, um *kernel* não-linear, apesar de diminuir as taxas de erro, teve desempenho inferior ao de outros modelos de aprendizagem de máquina aqui apresentados. Além disso, os modelos SVM levaram muito mais tempo de processamento do que outros. No entanto, esta não era uma questão importante, porque todos os modelos juntos levaram pouco menos de um minuto para serem executados. Embora *bagging*, *boosting* e *random forest* incorporem procedimentos semelhantes, RF geralmente produz melhores taxas de precisão e erro.

Um problema crítico geralmente encontrada em Redes Neurais é na oscilação dos dados de saídas. Por outro lado, os modelos de aprendizagem de máquina produzem soluções estáveis.

O risco de crédito e, mais especificamente, a previsão de inadimplência tem muito a ser investigada na obtenção de modelos referentes a variáveis macroeconômicas. Diversos trabalhos têm encontrado relações entre as variáveis macroeconômicas e *default* (CHEN; WU, 2014; YURDAKUL, 2014; ALI; DALY, 2010; BONFIM, 2009). Escolheu-se não aplicá-los, porque o efeito em termos de medidas específicas das firmas ter produzido resultados impressionantes. Tal escolha pode ser uma limitação que poderia ser explorada em um estudo posterior. Além disso, dado o âmbito do presente estudo, são necessárias mais pesquisas sobre o impacto de variáveis macroeconômicas, como sustentabilidade, governança, risco soberano, os *spreads* de crédito e desempenho das empresas PME.

Estudos futuros também são necessários para estender a taxas de crescimento e/ou efeitos de tempo de todas as variáveis, incluindo medidas de crescimento, para estabelecer o impacto do tempo sobre os eventos de *default*. Os resultados também devem ser aplicados a instituição financeira individual, considerando aspectos específicos da instituição, tais como avaliações, perdas, capital econômico, e os *spreads* de crédito.

Em termos de utilidade deste trabalho para os profissionais, os resultados do estudo são muito interessantes. Bancos e gestores de risco podem investigar este modelo, porque o poder de predição é reforçado em relação a modelos anteriores, que poderiam melhorar sua análise de risco de crédito e, conseqüentemente, alcançar melhores lucros e diminuir as perdas.

5 Comentários Finais

Ao longo dos últimos 15 anos, a literatura científica abordou vários aspectos relacionados ao risco de crédito. Leitura e análise de artigos sobre o assunto mostram-nos algumas pistas sobre o que os pesquisadores têm observado em estudos de determinados efeitos, além dos impactos de eventos padrão em economias regionais e internacionais. No entanto, algumas questões não menos relevantes vão exigir uma teoria mais abrangente, como a mensuração do capital econômico baseado na classificação de risco, modelos simuladores, aplicações de técnicas computacionais mais recentes e a exploração de exposição à inadimplência. Esta parte do estudo incorporou as principais considerações para a proposição dos outros dois ensaios nesta tese, demonstrando lacunas de conhecimento que não foram explorados em publicações recentes e, de uma forma inexplicável, requer uma base teórica mais consistente.

Aproveitando tais considerações, analisou-se uma implementação do modelo de capital econômico para as instituições que pretende melhorar a sua própria posição de classificação de risco devido à posição atual da contraparte. Usou-se simulações de LGD, com base em uma modelagem probabilística para obter uma perspectiva de estratégias potenciais para os credores. Os resultados mostraram que um banco, ao emprestar para uma empresa com classificação A, teve a oportunidade de melhorar a sua posição de classificação, dependendo de uma (não muito) baixa LGD. A maior limitação deste estudo está na obtenção dos dados de LGD, que são muito difíceis de encontrar. Para a investigação futura, a relação entre PD e LGD pode ser inserida no modelo.

A terceira investigação testou a performance de classificação de métodos de aprendizagem de máquinas contra três métodos bem conhecidos: análise discriminante, regressão logística e redes neurais. Examinou-se técnicas computacionais como máquinas de vetores de suporte, *bagging*, *boosting* e *random forest* para classificar a falha e não-fracasso de empresas um ano antes do *default* usando variáveis *Z-Score* de Altman e os seis constructos de [Carton e Hofer \(2006\)](#). Explorou-se dados de quase 30 anos e comparou-se o desempenho entre todos os modelos propostos. Como resultado, em termos de precisão total, a habilidade de novos modelos foi sempre predominante. Considerando cada caso de classificação, máquinas de vetores de suporte, redes neurais e regressão logística apresentaram grande erro do tipo I, mas oposto a isso, a incidência de erro do tipo II foi muito alta. Além disso, a análise discriminante foi o pior modelo em todos os testes. As variáveis apresentaram um contexto importante porque as medidas de crescimento sinalizaram uma contribuição interessante para aumentar o poder de predição de cada modelo na pesquisa.

Espera-se que essa pesquisa possa colaborar para melhorar a investigação de

problemas de risco de crédito e, em particular, para estender esses estudos para a economia brasileira. Enquanto isso, análise de falências no Brasil continua a ser um desafio e dados LGD são praticamente impossíveis de se encontrar neste país, exceto na “caixa preta” dos bancos.

Referências Bibliográficas

- ACHARYA, V. V.; AMIHU, Y.; LITOV, L. [Creditor rights and corporate risk-taking](#). *Journal of Financial Economics*, Elsevier BV, v. 102, n. 1, p. 150–166, Oct 2011. ISSN 0304-405X.
- ACHARYA, V. V.; BHARATH, S. T.; SRINIVASAN, A. [Does industry-wide distress affect defaulted firms? Evidence from creditor recoveries](#). *Journal of Financial Economics*, Elsevier BV, v. 85, n. 3, p. 787–821, Sep 2007. ISSN 0304-405X.
- AGARWAL, V.; TAFFLER, R. [Comparing the performance of market-based and accounting-based bankruptcy prediction models](#). *Journal of Banking & Finance*, Elsevier BV, v. 32, n. 8, p. 1541–1551, Aug 2008. ISSN 0378-4266.
- ALHASHEL, B. [Sovereign Wealth Funds: A literature review](#). *Journal of Economics and Business*, v. 78, n. 1, p. 1 – 13, 2015. ISSN 0148-6195.
- ALI, A.; DALY, K. [Macroeconomic determinants of credit risk: Recent evidence from a cross country study](#). *International Review of Financial Analysis*, Elsevier BV, v. 19, n. 3, p. 165–171, Jun 2010. ISSN 1057-5219.
- ALLEN, F.; CARLETTI, E. [Credit risk transfer and contagion](#). *Journal of Monetary Economics*, Elsevier BV, v. 53, n. 1, p. 89–111, Jan 2006. ISSN 0304-3932.
- ALLEN, L. [The Basel Capital Accords and International Mortgage Markets: A Survey of the Literature](#). *Financial Markets Inst & Instr*, Wiley-Blackwell, v. 13, n. 2, p. 41–108, May 2004. ISSN 1468-0416.
- ALMEIDA, H.; PHILIPPON, T. [The Risk-Adjusted Cost of Financial Distress](#). *The Journal of Finance*, Wiley-Blackwell, v. 62, n. 6, p. 2557–2586, Nov 2007. ISSN 0022-1082.
- ALTMAN, E. I. [Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy](#). *The Journal of Finance*, Wiley-Blackwell, v. 23, n. 4, p. 589–609, Sep 1968. ISSN 0022-1082.
- ALTMAN, E. I. [Default recovery rates and LGD in credit risk modeling and practice: an updated review of the literature and empirical evidence](#). [S.l.], 2006.
- ALTMAN, E. I.; BRADY, B.; RESTI, A.; SIRONI, A. [The Link between Default and Recovery Rates: Theory, Empirical Evidence, and Implications](#). *The Journal of Business*, University of Chicago Press, v. 78, n. 6, p. 2203–2228, Nov 2005. ISSN 1537-5374.
- ALTMAN, E. I.; RIJKEN, H. A. [How rating agencies achieve rating stability](#). *Journal of Banking & Finance*, Elsevier BV, v. 28, n. 11, p. 2679–2714, Nov 2004. ISSN 0378-4266.
- ALTMAN, E. I.; SABATO, G. [Modelling Credit Risk for SMEs: Evidence from the U.S. Market](#). *Abacus*, Wiley-Blackwell, v. 43, n. 3, p. 332–357, Sep 2007. ISSN 1467-6281.

- ALTMAN, E. I.; SAUNDERS, A. [An analysis and critique of the BIS proposal on capital adequacy and ratings](#). *Journal of Banking & Finance*, Elsevier BV, v. 25, n. 1, p. 25–46, Jan 2001. ISSN 0378–4266.
- AMATO, J. D.; FURFINE, C. H. [Are credit ratings procyclical?](#) *Journal of Banking & Finance*, Elsevier BV, v. 28, n. 11, p. 2641–2677, Nov 2004. ISSN 0378–4266.
- ANGELINI, E.; TOLLO, G. di; ROLI, A. [A neural network approach for credit risk evaluation](#). *The Quarterly Review of Economics and Finance*, Elsevier BV, v. 48, n. 4, p. 733–755, Nov 2008. ISSN 1062–9769.
- ARTZNER, P.; DELBAEN, F. [Default Risk Insurance and Incomplete Markets](#). *Mathematical Finance*, Wiley-Blackwell, v. 5, n. 3, p. 187–195, Jul 1995. ISSN 1467–9965.
- BADE, B.; RÖSCH, D.; SCHEULE, H. [Default and Recovery Risk Dependencies in a Simple Credit Risk Model](#). *European Financial Management*, Wiley-Blackwell, v. 17, n. 1, p. 120–144, Dec 2010. ISSN 1354–7798.
- BADE, B.; RÖSCH, D.; SCHEULE, H. Empirical performance of LGD prediction models. *Journal of Risk Model Validation*, v. 5, n. 2, p. 25–44, Jun 2011.
- BAG, P.; JACOBS Jr., M. [Parsimonious exposure-at-default modeling for unfunded loan commitments](#). *The Journal of Risk Finance*, v. 13, n. 1, p. 77–94, 2011.
- BANGIA, A.; DIEBOLD, F. X.; KRONIMUS, A.; SCHAGEN, C.; SCHUERMAN, T. [Ratings migration and the business cycle, with application to credit portfolio stress testing](#). *Journal of Banking & Finance*, Elsevier BV, v. 26, n. 2-3, p. 445–474, Mar 2002. ISSN 0378–4266.
- BAO, J.; PAN, J.; WANG, J. [The Illiquidity of Corporate Bonds](#). *The Journal of Finance*, Wiley-Blackwell, v. 66, n. 3, p. 911–946, May 2011. ISSN 0022–1082.
- BATTISTON, S.; GATTI, D. D.; GALLEGATI, M.; GREENWALD, B.; STIGLITZ, J. E. [Credit chains and bankruptcy propagation in production networks](#). *Journal of Economic Dynamics and Control*, Elsevier BV, v. 31, n. 6, p. 2061–2084, Jun 2007. ISSN 0165–1889.
- BATTISTON, S.; GATTI, D. D.; GALLEGATI, M.; GREENWALD, B.; STIGLITZ, J. E. [Default cascades: When does risk diversification increase stability?](#) *Journal of Financial Stability*, Elsevier BV, v. 8, n. 3, p. 138–149, Sep 2012. ISSN 1572–3089.
- BEAVER, W. H. [Financial Ratios As Predictors of Failure](#). *Journal of Accounting Research*, JSTOR, v. 4, p. 71–111, 1966. ISSN 0021–8456.
- BEBER, A.; BRANDT, M. W.; KAVAJECZ, K. A. [Flight-to-Quality or Flight-to-Liquidity? Evidence from the Euro-Area Bond Market](#). *Review of Financial Studies*, Oxford University Press (OUP), v. 22, n. 3, p. 925–957, Jan 2007. ISSN 1465–7368.
- BEGLEY, J.; MING, J.; WATTS, S. [Bankruptcy classification errors in the 1980s: An empirical analysis of Altman’s and Ohlson’s models](#). *Review of Accounting Studies*, Springer Science + Business Media, v. 1, n. 4, p. 267–284, 1996. ISSN 1573–7136.
- BELLOVARY, J.; GIACOMINO, D.; AKERS, M. A review of bankruptcy prediction studies: 1930 to present. *Journal of Financial Education*, v. 33, p. 1–43, 2007.

- BHAMRA, H. S.; KUEHN, L.-A.; STREBULAEV, I. A. [The Levered Equity Risk Premium and Credit Spreads: A Unified Framework](#). *Review of Financial Studies*, Oxford University Press (OUP), v. 23, n. 2, p. 645–703, Oct 2009. ISSN 1465–7368.
- BHARATH, S. T.; SHUMWAY, T. [Forecasting Default with the Merton Distance to Default Model](#). *Review of Financial Studies*, Oxford University Press (OUP), v. 21, n. 3, p. 1339–1369, Mar 2008. ISSN 1465–7368.
- BIELECKI, T. R.; JIN, H.; PLISKA, S. R.; ZHOU, X. Y. [Continuous-Time Mean-Variance Portfolio Selection With Bankruptcy Prohibition](#). *Mathematical Finance*, Wiley-Blackwell, v. 15, n. 2, p. 213–244, Apr 2005. ISSN 1467–9965.
- BLACK, F.; SCHOLES, M. [The Pricing of Options and Corporate Liabilities](#). *J Polit Econ*, University of Chicago Press, v. 81, n. 3, p. 637–654, Jan 1973. ISSN 1537–534X.
- BONFIM, D. [Credit risk drivers: Evaluating the contribution of firm level information and of macroeconomic dynamics](#). *Journal of Banking & Finance*, Elsevier BV, v. 33, n. 2, p. 281–299, Feb 2009. ISSN 0378–4266.
- BOOT, A. W. A.; MILBOURN, T. T.; SCHMEITS, A. [Credit Ratings as Coordination Mechanisms](#). *Review of Financial Studies*, Oxford University Press (OUP), v. 19, n. 1, p. 81–118, Oct 2005. ISSN 1465–7368.
- BOOTH, A.; GERDING, E.; MCGROARTY, F. [Automated trading with performance weighted random forests and seasonality](#). *Expert Systems with Applications*, Elsevier BV, v. 41, n. 8, p. 3651–3661, Jun 2014. ISSN 0957–4174.
- BOTHA, M.; VUUREN, G. V. Retail credit capital charge optimisation and the new Basel Accord. *Journal of Risk Management in Financial Institutions*, Henry Stewart, v. 2, n. 3, p. 265–283, 2009.
- BREIMAN, L. [Bagging Predictors](#). *Mach. Learn.*, Kluwer Academic Publishers, v. 24, n. 2, p. 123–140, ago. 1996. ISSN 0885–6125.
- BREIMAN, L. [Random Forests](#). *Mach. Learn.*, Kluwer Academic Publishers, v. 45, n. 1, p. 5–32, out. 2001. ISSN 0885–6125.
- BRISSIMIS, S. N.; DELIS, M. D.; PAPANIKOLAOU, N. I. [Exploring the nexus between banking sector reform and performance: Evidence from newly acceded EU countries](#). *Journal of Banking & Finance*, Elsevier BV, v. 32, n. 12, p. 2674–2683, Dec 2008. ISSN 0378–4266.
- BROWN, C. O.; DINC, I. S. [Too Many to Fail? Evidence of Regulatory Forbearance When the Banking Sector Is Weak](#). *Review of Financial Studies*, Oxford University Press (OUP), v. 24, n. 4, p. 1378–1405, May 2009. ISSN 1465–7368.
- CALDERONI, L.; FERRARA, M.; FRANCO, A.; MAIO, D. [Indoor localization in a hospital environment using Random Forest classifiers](#). *Expert Systems with Applications*, Elsevier BV, v. 42, n. 1, p. 125–134, Jan 2015. ISSN 0957–4174.
- CAMPBELL, J. Y.; HILSCHER, J.; SZILAGYI, J. [In Search of Distress Risk](#). *The Journal of Finance*, Wiley-Blackwell, v. 63, n. 6, p. 2899–2939, Dec 2008. ISSN 1540–6261.

- CANTOR, R. [An introduction to recent research on credit ratings](#). *Journal of Banking & Finance*, Elsevier BV, v. 28, n. 11, p. 2565–2573, Nov 2004. ISSN 0378–4266.
- CAOQUETTE, J. B.; ALTMAN, E. I.; NARAYANAN, P.; NIMMO, R. [Managing Credit Risk](#). 2nd.. ed. [S.l.]: John Wiley & Sons, Inc., 2008. ISBN <http://id.crossref.org/isbn/9780470118726>.
- CAREY, M. [Credit Risk in Private Debt Portfolios](#). *The Journal of Finance*, Wiley-Blackwell, v. 53, n. 4, p. 1363–1387, Aug 1998. ISSN 1540–6261.
- CAREY, M.; GORDY, M. [Measuring Systematic Risk in Recoveries on Defaulted Debt I: Firm-Level Ultimate LGDs](#). [S.l.]: FDIC: CFR Spring 2005 Research Conference Paper (Draft Memo), 2004.
- CARLING, K.; JACOBSON, T.; LINDE, J.; ROSZBACH, K. [Corporate credit risk modeling and the macroeconomy](#). *Journal of Banking & Finance*, Elsevier BV, v. 31, n. 3, p. 845–868, Mar 2007. ISSN 0378–4266.
- CARTON, R.; HOFER, C. [Measuring Organizational Performance](#). [S.l.]: Edward Elgar Publishing, 2006.
- CASALIN, F.; DIA, E. [Adjustment costs, financial frictions and aggregate investment](#) . *Journal of Economics and Business*, v. 75, n. 0, p. 60 – 79, 2014. ISSN 0148–6195.
- CASTERMANS, G.; MARTENS, D.; GESTEL, T. V.; HAMERS, B.; BAESENS, B. [An overview and framework for PD backtesting and benchmarking](#). *Journal of the Operational Research Society*, Nature Publishing Group, v. 61, n. 3, p. 359–373, Jul 2009. ISSN 1476–9360.
- CHALERMCHATVICHIEEN, P.; JUMREORNVONG, S.; JIRAPORN, P. [Basel III, capital stability, risk-taking, ownership: Evidence from Asia](#). *Journal of Multinational Financial Management*, Elsevier BV, v. 28, p. 28–46, Dec 2014. ISSN 1042–444X.
- CHATTERJEE, S.; CORBAE, D.; NAKAJIMA, M.; RÍOS-RULL, J.-V. [A Quantitative Theory of Unsecured Consumer Credit with Risk of Default](#). *Econometrica*, The Econometric Society, v. 75, n. 6, p. 1525–1589, Nov 2007. ISSN 1468–0262.
- CHAVA, S.; PURNANANDAM, A. [Is Default Risk Negatively Related to Stock Returns?](#) *Review of Financial Studies*, Oxford University Press (OUP), v. 23, n. 6, p. 2523–2559, Jun 2010. ISSN 1465–7368.
- CHEN, H. [Macroeconomic Conditions and the Puzzles of Credit Spreads and Capital Structure](#). *The Journal of Finance*, Wiley-Blackwell, v. 65, n. 6, p. 2171–2212, Nov 2010. ISSN 0022–1082.
- CHEN, J.; CHOLLETE, L.; RAY, R. [Financial distress and idiosyncratic volatility: An empirical investigation](#). *Journal of Financial Markets*, Elsevier BV, v. 13, n. 2, p. 249–267, May 2010. ISSN 1386–4181.
- CHEN, L.; COLLIN-DUFRESNE, P.; GOLDSTEIN, R. S. [On the Relation Between the Credit Spread Puzzle and the Equity Premium Puzzle](#). *Review of Financial Studies*, Oxford University Press (OUP), v. 22, n. 9, p. 3367–3409, Aug 2008. ISSN 1465–7368.

CHEN, P.; WU, C. [Default prediction with dynamic sectoral and macroeconomic frailties](#). *Journal of Banking & Finance*, Elsevier BV, v. 40, p. 211–226, Mar 2014. ISSN 0378–4266.

COLLIN-DUFRESNE, P.; GOLDSTEIN, R. S.; MARTIN, J. S. [The Determinants of Credit Spread Changes](#). *The Journal of Finance*, Wiley-Blackwell, v. 56, n. 6, p. 2177–2207, Dec 2001. ISSN 1540–6261.

CORTES, C.; VAPNIK, V. [Support-Vector Networks](#). *Mach. Learn.*, Kluwer Academic Publishers, v. 20, n. 3, p. 273–297, set. 1995. ISSN 0885–6125.

CROSBIE, P. J.; BOHN, J. R. *Modeling Default Risk*. [S.l.], 2002.

CROUHY, M.; GALAI, D.; MARK, R. [A comparative analysis of current credit risk models](#). *Journal of Banking & Finance*, Elsevier BV, v. 24, n. 1–2, p. 59–117, Jan 2000. ISSN 0378–4266.

CSFB. *CREDITRISK+: A Credit Risk Management Framework*. [S.l.], 1997.

DAS, S. R. [Basel II: Correlation Related Issues](#). *Journal of Financial Services Research*, Springer Science + Business Media, v. 32, n. 1-2, p. 17–38, Jul 2007. ISSN 1573–0735.

DAS, T. K.; TENG, B.-S. [Trust, Control, and Risk in Strategic Alliances: An Integrated Framework](#). *Organization Studies*, SAGE Publications, v. 22, n. 2, p. 251–283, Mar 2001. ISSN 0170–8406.

DAVYDENKO, S. A.; FRANKS, J. R. [Do Bankruptcy Codes Matter? A Study of Defaults in France Germany and the U.K.](#) *The Journal of Finance*, Wiley-Blackwell, v. 63, n. 2, p. 565–608, Apr 2008. ISSN 1540–6261.

DEMIROGLU, C.; JAMES, C. M. [The role of private equity group reputation in LBO financing](#). *Journal of Financial Economics*, Elsevier BV, v. 96, n. 2, p. 306–330, May 2010. ISSN 0304–405X.

DEYOUNG, R.; FRAME, W. S.; GLENNON, D.; MCMILLEN, D. P.; NIGRO, P. [Commercial lending distance and historically underserved areas](#). *Journal of Economics and Business*, Elsevier BV, v. 60, n. 1-2, p. 149–164, Jan 2008. ISSN 0148–6195.

DOOLEY, M.; HUTCHISON, M. [Transmission of the U.S. subprime crisis to emerging markets: Evidence on the decoupling–recoupling hypothesis](#). *Journal of International Money and Finance*, Elsevier BV, v. 28, n. 8, p. 1331–1349, Dec 2009. ISSN 0261–5606.

DUFFIE, D.; ECKNER, A.; HOREL, G.; SAITA, L. [Frailty Correlated Default](#). *The Journal of Finance*, Wiley-Blackwell, v. 64, n. 5, p. 2089–2123, Oct 2009. ISSN 1540–6261.

DUFFIE, D.; LANDO, D. [Term Structures of Credit Spreads with Incomplete Accounting Information](#). *Econometrica*, The Econometric Society, v. 69, n. 3, p. 633–664, May 2001. ISSN 1468–0262.

DUFFIE, D.; SAITA, L.; WANG, K. [Multi-period corporate default prediction with stochastic covariates](#). *Journal of Financial Economics*, Elsevier BV, v. 83, n. 3, p. 635–665, Mar 2007. ISSN 0304–405X.

- DUFFIE, D.; SINGLETON, K. J. [Modeling term structures of defaultable bonds](#). *Review of Financial Studies*, Oxford University Press (OUP), v. 12, n. 4, p. 687–720, Oct 1999. ISSN 1465–7368.
- EDMISTER, R. O. [An Empirical Test of Financial Ratio Analysis for Small Business Failure Prediction](#). *The Journal of Financial and Quantitative Analysis*, JSTOR, v. 7, n. 2, p. 1477–1493, Mar 1972. ISSN 0022–1090.
- ELYASIANI, E.; GOLDBERG, L. G. [Relationship lending: a survey of the literature](#). *Journal of Economics and Business*, Elsevier BV, v. 56, n. 4, p. 315–330, Jul 2004. ISSN 0148–6195.
- EOM, Y. H.; HELWEGE, J.; HUANG, J.-Z. [Structural Models of Corporate Bond Pricing: An Empirical Analysis](#). *Review of Financial Studies*, Oxford University Press (OUP), v. 17, n. 2, p. 499–544, Oct 2003. ISSN 1465–7368.
- ERICSSON, J.; JACOBS, K.; OVIEDO, R. [The Determinants of Credit Default Swap Premia](#). *JFQ*, Cambridge University Press (CUP), v. 44, n. 01, p. 109, Feb 2009. ISSN 1756–6916.
- ERICSSON, J.; RENAULT, O. [Liquidity and Credit Risk](#). *The Journal of Finance*, Wiley-Blackwell, v. 61, n. 5, p. 2219–2250, Oct 2006. ISSN 1540–6261.
- ERRAIS, E.; GIESECKE, K.; GOLDBERG, L. R. [Affine Point Processes and Portfolio Credit Risk](#). *SIAM J. Finan. Math.*, Society for Industrial & Applied Mathematics (SIAM), v. 1, n. 1, p. 642–665, Jan 2010. ISSN 1945–497X.
- ESPOSITO, F. P. Credit risk tools: an overview. *Journal of Advanced Studies in Finance (JASF)*, v. 2, n. 1, p. 18–25, 2011.
- EVANOFF, D. D.; JAGTIANI, J. A.; NAKATA, T. [Enhancing market discipline in banking: The role of subordinated debt in financial regulatory reform](#). *Journal of Economics and Business*, Elsevier BV, v. 63, n. 1, p. 1–22, Jan 2011. ISSN 0148–6195.
- FITCHRATINGS. [Definitions of ratings and other forms of opinion](#). *December*, 2014.
- FOOS, D.; NORDEN, L.; WEBER, M. [Loan growth and riskiness of banks](#). *Journal of Banking & Finance*, Elsevier BV, v. 34, n. 12, p. 2929–2940, Dec 2010. ISSN 0378–4266.
- FORTE, S.; PEÑA, J. I. [Credit spreads: An empirical analysis on the informational content of stocks, bonds, and CDS](#). *Journal of Banking & Finance*, Elsevier BV, v. 33, n. 11, p. 2013–2025, Nov 2009. ISSN 0378–4266.
- FREEMAN, M. C.; COX, P. R.; WRIGHT, B. [Credit risk management](#). *Managerial Finance*, v. 32, n. 9, p. 761–773, 2006.
- FREUND, Y.; SCHAPIRE, R. E. [A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting](#). *Journal of Computer and System Sciences*, Elsevier BV, v. 55, n. 1, p. 119–139, Aug 1997. ISSN 0022–0000.
- FRYE, J.; JACOBS Jr., M. Credit loss and systematic loss given default. *Journal of Credit Risk*, v. 8, n. 1, p. 1–32, 2012.

- GALINDO, J.; TAMAYO, P. [Credit Risk Assessment Using Statistical and Machine Learning: Basic Methodology and Risk Modeling Applications](#). *Computational Economics*, Springer Science + Business Media, v. 15, n. 1/2, p. 107–143, 2000. ISSN 0927–7099.
- GALLEGATI, M.; RAMSEY, J. B. [The forward looking information content of equity and bond markets for aggregate investments](#). *Journal of Economics and Business*, v. 75, n. 0, p. 1 – 24, 2014. ISSN 0148–6195.
- GEORGE, T. J.; HWANG, C.-Y. [A resolution of the distress risk and leverage puzzles in the cross section of stock returns](#). *Journal of Financial Economics*, Elsevier BV, v. 96, n. 1, p. 56–79, Apr 2010. ISSN 0304–405X.
- GIESE, G. The impact of PD/LGD correlations on credit risk capital. *Risk*, Financial Risk Management News and Analysis, v. 18, n. 4, p. 79–84, 2005.
- GIESECKE, K. *Credit Risk Modeling and Valuation: An Introduction In Credit Risk: Models and Management, Vol. 2*. [S.l.]: Riskbooks, 2004. 487–525 p.
- GLAESER, E. L.; LAIBSON, D. I.; SCHEINKMAN, J. A.; SOUTTER, C. L. [Measuring Trust](#). *Quarterly Journal of Economics*, Oxford University Press (OUP), v. 115, n. 3, p. 811–846, Aug 2000. ISSN 1531–4650.
- GOPALAN, R.; NANDA, V.; SERU, A. [Affiliated firms and financial support: Evidence from Indian business groups](#). *Journal of Financial Economics*, Elsevier BV, v. 86, n. 3, p. 759–795, Dec 2007. ISSN 0304–405X.
- GORDY, M. B. [A comparative anatomy of credit risk models](#). *Journal of Banking & Finance*, Elsevier BV, v. 24, n. 1-2, p. 119–149, Jan 2000. ISSN 0378–4266.
- GORDY, M. B.; HOWELLS, B. [Procyclicality in Basel II: Can we treat the disease without killing the patient?](#) *Journal of Financial Intermediation*, Elsevier BV, v. 15, n. 3, p. 395–417, Jul 2006. ISSN 1042–9573.
- GOSS, A.; ROBERTS, G. S. [The impact of corporate social responsibility on the cost of bank loans](#). *Journal of Banking & Finance*, Elsevier BV, v. 35, n. 7, p. 1794–1810, Jul 2011. ISSN 0378–4266.
- GREENBAUM, S. I.; THAKOR, A. V. [Bank funding modes](#). *Journal of Banking & Finance*, Elsevier BV, v. 11, n. 3, p. 379–401, Sep 1987. ISSN 0378–4266.
- GRIFFIN, J. M.; LEMMON, M. L. [Book-to-Market Equity, Distress Risk, and Stock Returns](#). *The Journal of Finance*, Wiley-Blackwell, v. 57, n. 5, p. 2317–2336, Oct 2002. ISSN 1540–6261.
- GRIFFIN, J. M.; TANG, D. Y. [Did Subjectivity Play a Role in CDO Credit Ratings?](#) *The Journal of Finance*, Wiley-Blackwell, v. 67, n. 4, p. 1293–1328, Jul 2012. ISSN 0022–1082.
- GROPP, R.; VESALA, J.; VULPES, G. [Equity and Bond Market Signals as Leading Indicators of Bank Fragility](#). *Journal of Money, Credit, and Banking*, Johns Hopkins University Press, v. 38, n. 2, p. 399–428, 2006. ISSN 1538–4616.

GROSS, D. B. [An Empirical Analysis of Personal Bankruptcy and Delinquency](#). *Review of Financial Studies*, Oxford University Press (OUP), v. 15, n. 1, p. 319–347, Mar 2002. ISSN 1465–7368.

GRUNERT, J.; NORDEN, L.; WEBER, M. [The role of non-financial factors in internal credit ratings](#). *Journal of Banking & Finance*, Elsevier BV, v. 29, n. 2, p. 509–531, Feb 2005. ISSN 0378–4266.

GRUNERT, J.; WEBER, M. [Recovery rates of commercial lending: Empirical evidence for German companies](#). *Journal of Banking & Finance*, Elsevier BV, v. 33, n. 3, p. 505–513, Mar 2009. ISSN 0378–4266.

GUIISO, L.; SAPIENZA, P.; ZINGALES, L. [The Determinants of Attitudes toward Strategic Default on Mortgages](#). *The Journal of Finance*, Wiley-Blackwell, v. 68, n. 4, p. 1473–1515, Jul 2013. ISSN 0022–1082.

GÜNTAY, L.; HACKBARTH, D. [Corporate bond credit spreads and forecast dispersion](#). *Journal of Banking & Finance*, Elsevier BV, v. 34, n. 10, p. 2328–2345, Oct 2010. ISSN 0378–4266.

GUPTON, G. M.; FINGER, C. C.; BHATIA, M. *RiskMetrics Group*. [S.l.], 2007.

GUZMÁN, E. A. Duñez; VOSE, M. D. [No Free Lunch and Benchmarks](#). *Evol. Comput.*, MIT Press, v. 21, n. 2, p. 293–312, maio 2013. ISSN 1063–6560.

HACKBARTH, D.; MIAO, J.; MORELLEC, E. [Capital structure, credit risk, and macroeconomic conditions](#). *Journal of Financial Economics*, Elsevier BV, v. 82, n. 3, p. 519–550, Dec 2006. ISSN 0304–405X.

HANSON, S.; SCHUERMAN, T. [Confidence intervals for probabilities of default](#). *Journal of Banking & Finance*, Elsevier BV, v. 30, n. 8, p. 2281–2301, Aug 2006. ISSN 0378–4266.

HAQ, M.; HEANEY, R. [Factors determining European bank risk](#). *Journal of International Financial Markets, Institutions and Money*, Elsevier BV, v. 22, n. 4, p. 696–718, Oct 2012. ISSN 1042–4431.

HE, Z.; XIONG, W. [Rollover Risk and Credit Risk](#). *The Journal of Finance*, Wiley-Blackwell, v. 67, n. 2, p. 391–430, Mar 2012. ISSN 0022–1082.

HENNESSY, C. A.; WHITED, T. M. [How Costly Is External Financing? Evidence from a Structural Estimation](#). *The Journal of Finance*, Wiley-Blackwell, v. 62, n. 4, p. 1705–1745, Aug 2007. ISSN 1540–6261.

HEO, J.; YANG, J. Y. [AdaBoost based bankruptcy forecasting of Korean construction companies](#). *Applied Soft Computing*, Elsevier BV, v. 24, p. 494–499, Nov 2014. ISSN 1568–4946.

HERTZEL, M.; LI, Z.; OFFICER, M.; RODGERS, K. [Inter-firm linkages and the wealth effects of financial distress along the supply chain](#). *Journal of Financial Economics*, Elsevier BV, v. 87, n. 2, p. 374–387, Feb 2008. ISSN 0304–405X.

HILLEGEIST, S. A.; KEATING, E. K.; CRAM, D. P.; LUNDSTEDT, K. G. [Assessing the Probability of Bankruptcy](#). *Review of Accounting Studies*, Springer Science + Business Media, v. 9, n. 1, p. 5–34, Mar 2004. ISSN 1380–6653.

- HOGGSON, N. F. *Banking through the ages*. [S.l.]: Dodd, Mead & Company, 1926.
- HOUWELING, P.; VORST, T. [Pricing default swaps: Empirical evidence](#). *Journal of International Money and Finance*, Elsevier BV, v. 24, n. 8, p. 1200–1225, Dec 2005. ISSN 0261–5606.
- HUANG, X.; OOSTERLEE, C. W. Generalized beta regression models for random loss-given-default. *Journal of Credit Risk*, v. 7, n. 4, p. 45–70, 2011.
- HUANG, X.; ZHOU, H.; ZHU, H. [A framework for assessing the systemic risk of major financial institutions](#). *Journal of Banking & Finance*, Elsevier BV, v. 33, n. 11, p. 2036–2049, Nov 2009. ISSN 0378–4266.
- HULL, J.; PREDESCU, M.; WHITE, A. [The relationship between credit default swap spreads, bond yields, and credit rating announcements](#). *Journal of Banking & Finance*, Elsevier BV, v. 28, n. 11, p. 2789–2811, Nov 2004. ISSN 0378–4266.
- IVASHINA, V. [Asymmetric information effects on loan spreads](#). *Journal of Financial Economics*, Elsevier BV, v. 92, n. 2, p. 300–319, May 2009. ISSN 0304–405X.
- JABBOUR, C. J. C. [Environmental training in organisations: From a literature review to a framework for future research](#). *Resources, Conservation and Recycling*, Elsevier BV, v. 74, n. 1, p. 144–155, May 2013. ISSN 0921–3449.
- JACOBS Jr., M. An empirical study of exposure at default. *Journal of Advanced Studies in Finance*, v. 1, n. 1, p. 31–59, 2010.
- JAPPELLI, T.; PAGANO, M. [Information sharing, lending and defaults: Cross-country evidence](#). *Journal of Banking & Finance*, Elsevier BV, v. 26, n. 10, p. 2017–2045, Oct 2002. ISSN 0378–4266.
- JARROW, R. A.; PROTTER, P. Structural versus reduced form models: a new information based perspective. *Journal of Investment Management*, v. 2, n. 2, p. 1–10, 2004.
- JARROW, R. A.; TURNBULL, S. M. [Pricing Derivatives on Financial Securities Subject to Credit Risk](#). *The Journal of Finance*, Wiley-Blackwell, v. 50, n. 1, p. 53–85, Mar 1995. ISSN 0022–1082.
- JARROW, R. A.; TURNBULL, S. M. [The intersection of market and credit risk](#). *Journal of Banking & Finance*, Elsevier BV, v. 24, n. 1-2, p. 271–299, Jan 2000. ISSN 0378–4266.
- JARROW, R. A.; YU, F. [Counterparty Risk and the Pricing of Defaultable Securities](#). *The Journal of Finance*, Wiley-Blackwell, v. 56, n. 5, p. 1765–1799, Oct 2001. ISSN 1540–6261.
- JENSEN, M. C.; MECKLING, W. H. [Theory of the firm: Managerial behavior, agency costs and ownership structure](#). *Journal of Financial Economics*, Elsevier BV, v. 3, n. 4, p. 305–360, Oct 1976. ISSN 0304–405X.
- JEON, B. N.; WU, J. [Global banks and internal capital markets: Evidence from bank-level panel data in emerging economies](#). *Journal of Multinational Financial Management*, Elsevier BV, v. 28, p. 79–94, Dec 2014. ISSN 1042–444X.

- JIMÉNEZ, G.; ONGENA, S.; RÍOS-RULL, J.-V.; SAURINA, J. [Hazardous Times for Monetary Policy: What do Twenty-Three Million Bank Loans Say About the Effects of Monetary Policy on Credit Risk-Taking?](#) *Econometrica*, The Econometric Society, v. 82, n. 2, p. 463–505, 2014. ISSN 0012–9682.
- JIMÉNEZ, G.; SAURINA, J. [Collateral, type of lender and relationship banking as determinants of credit risk.](#) *Journal of Banking & Finance*, Elsevier BV, v. 28, n. 9, p. 2191–2212, Sep 2004. ISSN 0378–4266.
- JOKIVUOLLE, E.; PEURA, S. Rating targeting and dynamic economic capital. *Journal of Risk*, v. 12, n. 4, p. 3–13, 2010.
- JORION, P.; ZHANG, G. [Good and bad credit contagion: Evidence from credit default swaps.](#) *Journal of Financial Economics*, Elsevier BV, v. 84, n. 3, p. 860–883, Jun 2007. ISSN 0304–405X.
- JORION, P.; ZHANG, G. [Credit Contagion from Counterparty Risk.](#) *The Journal of Finance*, Wiley-Blackwell, v. 64, n. 5, p. 2053–2087, Oct 2009. ISSN 1540–6261.
- KANAS, A. [Default risk and equity prices in the U.S. banking sector: Regime switching effects of regulatory changes.](#) *Journal of International Financial Markets, Institutions and Money*, Elsevier BV, v. 33, n. 1, p. 244–258, Nov 2014. ISSN 1042–4431.
- KHANDANI, A. E.; KIM, A. J.; LO, A. W. [Consumer credit-risk models via machine-learning algorithms.](#) *Journal of Banking & Finance*, Elsevier BV, v. 34, n. 11, p. 2767–2787, Nov 2010. ISSN 0378–4266.
- KIM, M.-J.; KANG, D.-K. [Ensemble with neural networks for bankruptcy prediction.](#) *Expert Systems with Applications*, Elsevier BV, v. 37, n. 4, p. 3373–3379, Apr 2010. ISSN 0957–4174.
- KIM, S. Y.; UPNEJA, A. [Predicting restaurant financial distress using decision tree and AdaBoosted decision tree models.](#) *Economic Modelling*, Elsevier BV, v. 36, p. 354–362, Jan 2014. ISSN 0264–9993.
- KRUPPA, J.; SCHWARZ, A.; ARMINGER, G.; ZIEGLER, A. [Consumer credit risk: Individual probability estimates using machine learning.](#) *Expert Systems with Applications*, Elsevier BV, v. 40, n. 13, p. 5125–5131, Oct 2013. ISSN 0957–4174.
- Lage Junior, M.; Godinho Filho, M. [Variations of the kanban system: Literature review and classification.](#) *International Journal of Production Economics*, Elsevier BV, v. 125, n. 1, p. 13–21, May 2010. ISSN 0925–5273.
- LAI, V. S.; SOUMARÉ, I. [Risk-Based Capital and Credit Insurance Portfolios.](#) *Financial Markets, Institutions & Instruments*, Wiley-Blackwell, v. 19, n. 1, p. 21–45, Feb 2010. ISSN 1468–0416.
- LI, H.; SUN, J. [Gaussian case-based reasoning for business failure prediction with empirical data in China.](#) *Information Sciences*, Elsevier BV, v. 179, n. 1-2, p. 89–108, Jan 2009. ISSN 0020–0255.
- LIN, C.; MA, Y.; MALATESTA, P.; XUAN, Y. [Ownership structure and the cost of corporate borrowing.](#) *Journal of Financial Economics*, Elsevier BV, v. 100, n. 1, p. 1–23, Apr 2011. ISSN 0304–405X.

- LOU, W.; YIN, X. [The impact of the global financial crisis on mortgage pricing and credit supply](#). *Journal of International Financial Markets, Institutions and Money*, Elsevier BV, v. 29, n. 1, p. 336–363, Mar 2014. ISSN 1042–4431.
- MANSI, S. A.; MAXWELL, W. F.; MILLER, D. P. [Does Auditor Quality and Tenure Matter to Investors? Evidence from the Bond Market](#). *J Accounting Res*, Wiley-Blackwell, v. 42, n. 4, p. 755–793, Sep 2004. ISSN 1475–679X.
- MAUDOS, J.; GUEVARA, J. F. de. [Factors explaining the interest margin in the banking sectors of the European Union](#). *Journal of Banking & Finance*, Elsevier BV, v. 28, n. 9, p. 2259–2281, Sep 2004. ISSN 0378–4266.
- MERTON, R. C. [On The Pricing of Corporate Debt: The Risk Structure of Interest Rates](#). *The Journal of Finance*, Wiley-Blackwell, v. 29, n. 2, p. 449–470, May 1974. ISSN 0022–1082.
- MIN, J.; LEE, Y. [Bankruptcy prediction using support vector machine with optimal choice of kernel function parameters](#). *Expert Systems with Applications*, Elsevier BV, v. 28, n. 4, p. 603–614, May 2005. ISSN 0957–4174.
- MODIGLIANI, F.; MILLER, M. H. The cost of capital, corporation finance and the theory of investment. *American Economic Review*, v. 48, n. 3, p. 261–297, 1958.
- Moody's Investors Service. *Historical Default rates of Corporate Bond Issuers 1920–1998*. [S.l.], 1999.
- Moody's Investors Service. *Default and Recovery Rates of Corporate Bond Issuers 1920–2002*. [S.l.], 2003.
- MORA, N. [What Determines Creditor Recovery Rates?](#) *Economic Review*, Second Quarter, p. 79–109, 2012.
- MORELLEC, E. [Can Managerial Discretion Explain Observed Leverage Ratios?](#) *Review of Financial Studies*, Oxford University Press (OUP), v. 17, n. 1, p. 257–294, Aug 2003. ISSN 1465–7368.
- NANNI, L.; LUMINI, A. [An experimental comparison of ensemble of classifiers for bankruptcy prediction and credit scoring](#). *Expert Systems with Applications*, Elsevier BV, v. 36, n. 2, p. 3028–3033, Mar 2009. ISSN 0957–4174.
- NEAGU, R.; KEENAN, S.; CHALERMKRAIVUTH, K. Internal credit rating systems: Methodology and economic value. *The Journal of Risk Model Validation*, v. 3, n. 2, p. 11–34, 2009.
- NEAL, R. S. Credit derivatives: new financial instruments for controlling credit risk. *Economic Review*, Federal Reserve Bank of Kansas City, v. 81, n. 1, p. 15–28, 1996.
- NICKELL, P.; PERRAUDIN, W.; VAROTTO, S. [Stability of rating transitions](#). *Journal of Banking & Finance*, Elsevier BV, v. 24, n. 1-2, p. 203–227, Jan 2000. ISSN 0378–4266.
- NOBLE, W. S. [What is a support vector machine?](#) *Nature Biotechnology*, Nature Publishing Group, v. 24, n. 12, p. 1565–1567, Dec 2006. ISSN 1087–0156.
- NORDEN, L.; WAGNER, W. [Credit Derivatives and Loan Pricing](#). *Journal of Banking & Finance*, Elsevier BV, v. 32, n. 12, p. 2560–2569, Dec 2008. ISSN 0378–4266.

NORDEN, L.; WEBER, M. [The Co-movement of Credit Default Swap, Bond and Stock Markets: an Empirical Analysis](#). *European Financial Management*, Wiley-Blackwell, v. 15, n. 3, p. 529–562, Jun 2009. ISSN 1468–036X.

OHLSON, J. A. [Financial Ratios and the Probabilistic Prediction of Bankruptcy](#). *Journal of Accounting Research*, JSTOR, v. 18, n. 1, p. 109–131, 1980. ISSN 0021–8456.

OJO, M. [Risk management by the Basel Committee: Evaluating progress made from the 1988 Basel Accord to recent developments](#). *Journal of Financial Regulation and Compliance*, Emerald, v. 18, n. 4, p. 305–315, 2010. ISSN 1358–1988.

ONG, M. *Internal Credit Risk Models: Capital Allocation and Performance Measurement*. [S.l.]: Risk Books, 1999. 364 p. ISBN 9781899332038.

OSKOEI, M.; HU, H. [Support Vector Machine-Based Classification Scheme for Myoelectric Control Applied to Upper Limb](#). *IEEE Trans. Biomed. Eng.*, Institute of Electrical & Electronics Engineers (IEEE), v. 55, n. 8, p. 1956–1965, Aug 2008. ISSN 1558–2531.

OSUNA, E.; FREUND, R.; GIROSI, F. Training support vector machines: an application to face detection. In: IEEE. *Computer Vision and Pattern Recognition, 1997. Proceedings., 1997 IEEE Computer Society Conference on*. [S.l.], 1997. p. 130–136.

POON, S.-H. [Extreme Value Dependence in Financial Markets: Diagnostics, Models, and Financial Implications](#). *Review of Financial Studies*, Oxford University Press (OUP), v. 17, n. 2, p. 581–610, Oct 2003. ISSN 1465–7368.

PRABHA, A. P.; WIHLBORG, C. [Implicit guarantees, business models and banks? risk-taking through the crisis: Global and European perspectives](#). *Journal of Economics and Business*, v. 76, n. 0, p. 10 – 38, 2014. ISSN 0148–6195.

ROSENBERG, J. V.; SCHUERMANN, T. [A general approach to integrated risk management with skewed, fat-tailed risks](#). *Journal of Financial Economics*, Elsevier BV, v. 79, n. 3, p. 569–614, Mar 2006. ISSN 0304–405X.

SCHAEFER, S. M.; STREBULAEV, I. A. [Structural models of credit risk are useful: Evidence from hedge ratios on corporate bonds](#). *Journal of Financial Economics*, Elsevier BV, v. 90, n. 1, p. 1–19, Oct 2008. ISSN 0304–405X.

SCHUERMANN, T. *What do we know about Loss Given Default?* [S.l.], 2004.

SEURING, S. [A review of modeling approaches for sustainable supply chain management](#). *Decision Support Systems*, Elsevier BV, v. 54, n. 4, p. 1513–1520, Mar 2013. ISSN 0167–9236.

SHEN, C.-H.; HUANG, Y.-L.; HASAN, I. [Asymmetric benchmarking in bank credit rating](#). *Journal of International Financial Markets, Institutions and Money*, Elsevier BV, v. 22, n. 1, p. 171–193, Feb 2012. ISSN 1042–4431.

SINKEY, J. F. [A Multivariate Statistical Analysis of the Characteristics of Problem Banks](#). *The Journal of Finance*, Wiley-Blackwell, v. 30, n. 1, p. 21–36, Mar 1975. ISSN 0022–1082.

Society of Actuaries. *1986-1998 Credit Risk Loss Experience Study: Private Placement Bonds*. 2002.

- Society of Actuaries. *1986-2002 Credit Risk Loss Experience Study: Private Placement Bonds*. 2006.
- STOIAN, N.; BALAN, M. Stochastic models for credit risk. *Internal Auditing and Risk Management*, Athenaeum University of Bucharest, v. 1, n. 26, p. 35–44, 2012.
- SUBASI, A.; GURSOY, M. I. [EEG signal classification using PCA, ICA, LDA and support vector machines](#). *Expert Systems with Applications*, Elsevier BV, v. 37, n. 12, p. 8659–8666, Dec 2010. ISSN 0957–4174.
- SUNDMACHER, M.; ELLIS, C. [Bank “ratings arbitrage”: Is LGD a blind spot in economic capital calculations?](#) *International Review of Financial Analysis*, Elsevier BV, v. 20, n. 1, p. 6–11, Jan 2011. ISSN 1057–5219.
- TAFFLER, R. J. [Empirical models for the monitoring of UK corporations](#). *Journal of Banking & Finance*, Elsevier BV, v. 8, n. 2, p. 199–227, Jun 1984. ISSN 0378–4266.
- TANG, D. Y.; YAN, H. [Market conditions, default risk and credit spreads](#). *Journal of Banking & Finance*, Elsevier BV, v. 34, n. 4, p. 743–753, Apr 2010. ISSN 0378–4266.
- TIAN, Y.; SHI, Y.; LIU, X. [Recent advances on support vector machines research](#). *Technological and Economic Development of Economy*, Vilnius Gediminas Technical University, v. 18, n. 1, p. 5–33, Mar 2012. ISSN 2029–4921.
- TRUSTORFF, J.-H.; KONRAD, P. M.; LEKER, J. [Credit risk prediction using support vector machines](#). *Rev Quant Finan Acc*, Springer Science + Business Media, v. 36, n. 4, p. 565–581, Jul 2010. ISSN 1573–7179.
- UPNEJA, A.; DALBOR, M. C. [An examination of capital structure in the restaurant industry](#). *International Journal of Contemporary Hospitality Management*, Emerald, v. 13, n. 2, p. 54–59, Apr 2001. ISSN 0959–6119.
- VASSALOU, M.; XING, Y. [Default Risk in Equity Returns](#). *The Journal of Finance*, Wiley-Blackwell, v. 59, n. 2, p. 831–868, Apr 2004. ISSN 1540–6261.
- VERONESI, P.; ZINGALES, L. [Paulson’s gift](#). *Journal of Financial Economics*, Elsevier BV, v. 97, n. 3, p. 339–368, Sep 2010. ISSN 0304–405X.
- VITHESSONTHI, C. [Financial markets development and bank risk: Experience from Thailand during 1990–2012](#). *Journal of Multinational Financial Management*, Elsevier BV, v. 27, p. 67–88, Oct 2014. ISSN 1042–444X.
- VITHESSONTHI, C.; TONGURAI, J. [The effect of firm size on the leverage–performance relationship during the financial crisis of 2007–2009](#). *Journal of Multinational Financial Management*, Elsevier BV, v. 29, p. 1–29, Feb 2015. ISSN 1042–444X.
- WANG, G.; HAO, J.; MA, J.; JIANG, H. [A comparative assessment of ensemble learning for credit scoring](#). *Expert Systems with Applications*, Elsevier BV, v. 38, n. 1, p. 223–230, Jan 2011. ISSN 0957–4174.
- WANG, G.; MA, J.; HUANG, L.; XU, K. [Two credit scoring models based on dual strategy ensemble trees](#). *Knowledge-Based Systems*, Elsevier BV, v. 26, p. 61–68, Feb 2012. ISSN 0950–7051.

- WANG, G.; MA, J.; YANG, S. [An improved boosting based on feature selection for corporate bankruptcy prediction](#). *Expert Systems with Applications*, Elsevier BV, v. 41, n. 5, p. 2353–2361, Apr 2014. ISSN 0957–4174.
- WENIGNER, A.; BURGHOF, H.-P.; SCHNEIDER, J. [The impact of credit rating announcements on corporate CDS markets– Are intra-industry effects observable?](#) *Journal of Economics and Business*, Elsevier BV, v. 78, p. 79–91, Mar 2015. ISSN 0148–6195.
- WILSON, T. Portfolio credit risk I. *Risk*, v. 10, n. 9, p. 111–117, 1997.
- WILSON, T. Portfolio credit risk II. *Risk*, v. 10, n. 10, p. 56–61, 1997.
- YU, F. [Accounting transparency and the term structure of credit spreads](#). *Journal of Financial Economics*, Elsevier BV, v. 75, n. 1, p. 53–84, Jan 2005. ISSN 0304–405X.
- YU, L.; YUE, W.; WANG, S.; LAI, K. [Support vector machine based multiagent ensemble learning for credit risk evaluation](#). *Expert Systems with Applications*, Elsevier BV, v. 37, n. 2, p. 1351–1360, Mar 2010. ISSN 0957–4174.
- YURDAKUL, F. [Macroeconomic Modelling of Credit Risk for Banks](#). *Procedia - Social and Behavioral Sciences*, Elsevier BV, v. 109, p. 784–793, Jan 2014. ISSN 1877–0428.
- ZHANG, Z.; SONG, W.; SUN, X.; SHI, N. [Subordinated debt as instrument of market discipline: Risk sensitivity of sub-debt yield spreads in UK banking](#). *Journal of Economics and Business*, Elsevier BV, v. 73, p. 1–21, May 2014. ISSN 0148–6195.
- ZHAO, Z.; XU, S.; KANG, B. H.; KABIR, M. M. J.; LIU, Y.; WASINGER, R. [Investigation and improvement of multi-layer perception neural networks for credit scoring](#). *Expert Systems with Applications*, Elsevier BV, in press, Dec 2014. ISSN 0957–4174.
- ZHOU, C. [The term structure of credit spreads with jump risk](#). *Journal of Banking & Finance*, Elsevier BV, v. 25, n. 11, p. 2015–2040, Nov 2001. ISSN 0378–4266.
- ZHOU, L.; LAI, K. K.; YEN, J. [Bankruptcy prediction using SVM models with a new approach to combine features selection and parameter optimisation](#). *International Journal of Systems Science*, Informa UK Limited, v. 45, n. 3, p. 241–253, Apr 2014. ISSN 1464–5319.
- ZHU, H. [An Empirical Comparison of Credit Spreads between the Bond Market and the Credit Default Swap Market](#). *J Finan Serv Res*, Springer Science + Business Media, v. 29, n. 3, p. 211–235, May 2006. ISSN 1573–0735.