UNIVERSIDADE DE SÃO PAULO
FACULDADE DE ECONOMIA, ADMINISTRAÇÃO E CONTABILIDADE DE RIBEIRÃO PRETO
DEPARTAMENTO DE CONTABILIDADE
PROGRAMA DE PÓS-GRADUAÇÃO EM CONTROLADORIA E CONTABILIDADE

FILIPE CASELLATO SCABORA

Fatores determinantes da recuperação judicial considerando os fluxos de caixa das firmas

ORIENTADOR: Prof. Dr. Marcelo Botelho da Costa Moraes

RIBEIRÃO PRETO
2019

Prof. Dr. Vahan Agopyan
Reitor da Universidade de São Paulo

Prof. Dr. André Lucirton Costa
Diretor da Faculdade de Economia, Administração e Contabilidade de Ribeirão Preto

Prof. Dr. Fabiano Guasti Lima
Chefe do Departamento de Contabilidade

Prof. Dr. Amaury José Rezende
Coordenador do Programa de Pós-Graduação em Controladoria e Contabilidade

FILIPE CASELLATO SCABORA

Fatores determinantes da recuperação judicial considerando os fluxos de caixa das firmas

Dissertação apresentada ao Programa de Pós-Graduação em Controladoria e Contabilidade da Faculdade de Economia, Administração e Contabilidade de Ribeirão Preto da Universidade de São Paulo como requisito para obtenção do título de Mestre em Ciências. Versão corrigida. A versão original encontra-se disponível na FEAR-RP.

Orientador: Prof. Dr. Marcelo Botelho da Costa Moraes

RIBEIRÃO PRETO

2019

Autorizo a reprodução e divulgação total ou parcial deste trabalho, por qualquer meio convencional ou eletrônico, para fins de estudo e pesquisa, desde que citada a fonte.

FICHA CATALOGRÁFICA

Scabora, Filipe Casellato
Fatores determinantes da recuperação judicial considerando os fluxos de caixa das firmas / Ribeirão Preto – 2019.
77 f.: il

Dissertação de mestrado apresentada à Faculdade de Economia, Administração e Contabilidade de Ribeirão Preto da Universidade de São Paulo.
Área de concentração: Controladoria e Contabilidade

Orientador: Moraes, Marcelo Botelho da Costa.

1. Recuperação judicial. 2. Previsão. 3. Fluxo de caixa.

FICHA DE APROVAÇÃO

Nome: SCABORA, Filipe Casellato

Título: Fatores determinantes da recuperação judicial considerando os fluxos de caixa das firmas

Dissertação apresentada ao Programa de Pós-Graduação em Controladoria e Contabilidade da Faculdade de Economia, Administração e Contabilidade de Ribeirão Preto da Universidade de São Paulo, como requisito para obtenção do título de Mestre em Ciências.

Orientador: Prof. Dr. Marcelo Botelho da Costa Moraes

Aprovado em:

Banca Examinadora

Prof. Dr. _____ Instituição: _____

Julgamento: _____ Assinatura: _____

Prof. Dr. _____ Instituição: _____

Julgamento: _____ Assinatura: _____

Prof. Dr. _____ Instituição: _____

Julgamento: _____ Assinatura: _____

AGRADECIMENTOS

Primeiramente, agradeço à Faculdade de Economia, Administração e Contabilidade de Ribeirão Preto da Universidade de São Paulo, na figura do meu orientador, Prof. Dr. Marcelo Botelho da Costa Moraes, sem quem esse trabalho não teria sido possível: ao mestre dizer obrigado temos.

Agradeço também à minha família, em especial àqueles que já não mais estão aqui e cujo orgulho de todas as pequenas e grandes conquistas sempre foi uma fonte de inspiração; à minha irmã, Laís Casellato Scabora, que sempre fez (e continua fazendo) o papel de *checks and balances*.

Victor Estima e Isabela El Assal, que estiverem presentes na *darkest hour* e podem até não saber, mas não teria chegado até aqui sem o apoio de ambos: amo vocês, lixos. Diego da Silva Leite, novamente por aqui, cumprindo o papel de irmão e Arthur Mendonça, mais uma vez no papel de filho (pródigo): só posso dizer obrigado por estarem sempre aí.

Aos meus sócios e toda a equipe de Passos e Sticca Advogados Associados, cujo suporte foi (e é) imprescindível: Lucas Pimentel, Leonardo Gibertoni, Vinicius Rozenfeld, Lucas Kobayashi e Bruno Rezende vocês são responsáveis por muitas discussões e debates que, de certa forma, estão incorporados não apenas neste texto, mas também na visão de mundo em construção.

"*Este é o meu corpo, ele disse há dois mil anos. Este é o meu sangue. Era a única religião que proporcionava exatamente o que prometia: vida eterna para seus seguidores. Alguns de nós, que vivemos hoje, se lembram dele. E alguns de nós alegam que ele foi um messias, enquanto outros acham que era apenas um homem com poderes muito especiais. Mas isso não vem ao caso. Fosse o que fosse, ele mudou o mundo*"

(Fragile Things, Neil Gaiman).

“*Nothing's ever the same," she said. "Be it a second later or a hundred years. It's always churning and roiling. And people change as much as oceans*.”

Neil Gaiman, The Ocean at the End of the Lane

RESUMO

SCABORA, Filipe Casellato. **Fatores determinantes da recuperação judicial considerando os fluxos de caixa das firmas**. 2019. 76 f. Dissertação (Mestrado) – Faculdade de Economia, Administração e Contabilidade de Ribeirão Preto, Universidade de São Paulo, 2019.

Os efeitos da insolvência das organizações para os credores, acionistas e a sociedade em geral (*stakeholders*) levou, desde o início dos anos 1930, inúmeros pesquisadores a investigarem as causas da falência, desenvolvendo modelos que buscassem prever (e prevenir) a ocorrência desses eventos. Ao longo dos anos, e com o desenvolvimento de novas ferramentas e tecnologias no campo da estatística e informática, esses modelos foram submetidos a um processo de evolução, o que permite, hoje, identificar-lhes por meio de seus componentes histórico-cronológicos, como sendo modelos teóricos (que focam nas causas qualitativas da falência), estatísticos (que focam nos sintomas da falência) e de inteligência artificial (que também focam nos sintomas da falência, mas com um componente tecnológico adicional). Os chamados modelos estatísticos destacaram-se, desde cedo, como parte do *mainstream* da pesquisa em previsão de insolvência, o que levou a uma concentração das pesquisas na área, mesmo em tempos mais recentes, quando o desenvolvimento tecnológico demonstra que os modelos de inteligência artificial podem apresentar resultados melhores. Muito além da controvérsia em torno da eficácia da grande maioria desses modelos para dados brasileiros, outros fatores justificam a necessidade de novos trabalhos na área: (i) o Brasil e o mundo experimentam, desde a crise mundial de 2008, um crescimento no número de falências e recuperações judiciais; (ii) no país, o advento da LRF em 2005 modificou significativamente o mapa de falências com a introdução da figura da recuperação judicial; e, por fim, (iii) as pesquisas na área, em sua maioria, além de adotarem modelos estatísticos clássicos, consideram como evento de interesse que pretendem observar, a ocorrência da falência ou a constatação da insolvência (técnica ou baseada em fluxos), quando, na verdade, existem inúmeros elementos que demonstram a supremacia da recuperação judicial como evento determinante a ser investigado. Outro fator que distingue os modelos clássicos dos modelos de inteligência artificial diz respeito a seleção das variáveis, majoritariamente indicadores financeiros extraídos de BP e DRE, mesmo diante das evidências de que os fluxos de caixa têm impacto mais decisivo nos ciclos de vida das organizações, o que inclui a necessidade de buscarem ferramentas para superar períodos de crise, como a recuperação judicial e a falência. Portanto, o objetivo desta pesquisa consiste no desenvolvimento de um modelo de previsão para dados brasileiros, que investigue, por intermédio das RNA, a existência de relação entre certos componentes da DFC e o fato de a entidade apresentar (ou não) pedido de recuperação judicial como alternativa a insolvência, permitindo, ainda, a estimação desse lapso temporal. Espera-se que o modelo proposto seja capaz de aprimorar a capacidade preditiva da recuperação judicial em comparação com os modelos atuais e forneça maiores informações sobre as organizações em estado de insolvência, com inúmeras aplicações para o mercado e a academia.

Palavras-chave: Recuperação judicial. Previsão. Fluxo de caixa.

ABSTRACT

SCABORA, Filipe Casellato. **Determinants of judicial reorganization considering the cash flows of firms**. 2019. 76 f. Dissertação (Mestrado) – Faculdade de Economia, Administração e Contabilidade de Ribeirão Preto, Universidade de São Paulo, 2019.

From the beginning of the 1930s onwards, the effects of insolvency on creditors, shareholders and society (stakeholders) led researchers to investigate the causes of bankruptcy and developing forecasting models to predict (and prevent) its occurrence. Over the years, the technological development in the fields of statistics and computer science conducted an evolution of these models, which allows to identify them through their historical-chronological components, as theoretical (focusing on the qualitative causes of bankruptcy), statistical (focusing on the symptoms of bankruptcy) and artificial intelligence ones (also focusing on the symptoms of bankruptcy, but with an additional technological component). So-called statistical models have early emerged as part of the mainstream of insolvency forecasting, concentrating the researches on the field even before recent demonstrations that artificial intelligence models may present better results. Beyond the controversy over the effectiveness of these models for Brazilian data, other factors justify new researches: (i) Brazil and abroad experience since the 2008 crisis a growth in the number of bankruptcies and judicial reorganization, (ii) Brazilian LRF of 2005 significantly modified the bankruptcy map introducing the judicial reorganization in the country, (iii) most researches adopt classic statistical models and consider the occurrence of bankruptcy or insolvency (flow-based or stock-based) as the main forecasting event despite of evidences that demonstrate the superiority of judicial recovery as the determining event to be investigated. Another factor that distinguishes both classic and artificial intelligence models involves the selection of variables, mostly financial indicators from BP and DRE, even before evidences supporting that cash flows impact decisively the firm life cycles, including decisions to overcome periods of crisis, such as seeking for judicial reorganization or bankruptcy. Therefore, the objective of this research is to develop a prediction model for Brazilian data, which investigates, through RNA, the existence of a relationship between certain components of the DFC and the judicial reorganization of the firms as well as make possible the estimation of the time lapse until the occurrence of the event (judicial reorganization). It is expected that the proposed model will be able to enhance the prediction of judicial reorganization in comparison with current models and provide more information on insolvent firms with numerous applications for market and other researches purposes.

Keywords: Reorganization. Forecasting. Cash Flow.

LISTA DE FIGURAS

Figura 1 – Insolvência técnica e insolvência baseada em saldo 25
Figura 2 - Fluxograma simplificado da recuperação judicial 27
Figura 3 - Representação de uma RNA 50

LISTA DE GRÁFICOS

Gráfico 1 – As maiores recuperações judiciais do Brasil (em bilhões de Reais) 17
Gráfico 2 - Evolução dos pedidos de recuperação judicial no Brasil.....30
Gráfico 3 - Evolução dos pedidos de concordata no Brasil.....30
Gráfico 4 - Falências, recuperações judiciais e concordatas 31

LISTA DE TABELAS

Tabela 1 - Classificação dos modelos de previsão de insolvência 22
Tabela 2 - Falências, recuperações judiciais e concordatas.....28
Tabela 3 - Pedidos de concordata e recuperação.....29
Tabela 4 - Principais modelos de previsão de insolvência e suas variáveis 36
Tabela 5 - Frequência dos indicadores envolvendo fluxo de caixa.....38
Tabela 6 - Variáveis contábeis selecionadas 40
Tabela 7 - Variáveis macroeconômicas e de mercado 41
Tabela 8 - Comportamento dos fluxos de caixa no ciclo de vida das organizações.....42
Tabela 9 - Variáveis de fluxo de caixa propostas.....42
Tabela 10 - Variáveis selecionadas 43
Tabela 11 – Distribuição setorial da amostra e do grupo de controle 46
Tabela 12 - Estatística descritiva.....46
Tabela 13 - Técnicas de regressão aplicadas.....52
Tabela 14 – Testes de normalidade e multicolinearidade.....54
Tabela 15 – Teste de heterocedasticidade 54
Tabela 16 – Regressão linear – f(RJ) 55
Tabela 17 – LOGIT – f(RJ).....55
Tabela 18 – Classificação estatística – f(RJ).....56
Tabela 19 – Regressão linear – f(T) 56
Tabela 20 – *Cross-validation test* – RJ.....58
Tabela 21 – Classificações corretas – RJ.....58
Tabela 22 – RMSE – RJ 59
Tabela 23 – Correlação dos atributos (RJ) 59
Tabela 24 – *Cross-validation* teste – T.....60
Tabela 25 – Coeficiente de Correlação entre previsto e observado 60
Tabela 26 – RMSE – T 61
Tabela 27 – Correlação dos atributos (T).....61
Tabela 28 – Melhores classificações– RJ 62
Tabela 29 – Comparativo RNA x regressão linear - RJ 62
Tabela 30 – Matriz de confusão 63
Tabela 31 – Melhores classificações– T.....64
Tabela 32 – Correlação dos atributos (RJ e T).....65

LISTA DE SIGLAS

AC	Ativo Circulante
AGC	Assembleia Geral de Credores
ANC	Ativo Não Circulante
AP	Ativo Permanente
ARLP	Ativo Realizável a Longo Prazo
AT	Ativo Total
B3	Bolsa de Valores – Brasil, Bolsa, Balcão
BP	Balanço Patrimonial
CFS	*Correlation based Feature Selection*
CF/88	Constituição Federal de 1988
CG	Capital Giro
CGL	Capital Giro Líquido
CPC	Comitê de Pronunciamentos Contábeis
CS	Capital Social
CVM	Comissão de Valores Mobiliários
DFC	Demonstração de Fluxo de Caixa
DL	Decreto-Lei
DRE	Demonstração do Resultado do Exercício
EBIT	*Earnings Before Interests and Taxes*
FASB	*Financial Accounting Standards Board*
FCF	Fluxo de Caixa de Financiamento
FCI	Fluxo de Caixa de Investimento
FCO	Fluxo de Caixa Operacional
IAS	*International Accounting Standard*
IFRS	*International Financial Reporting Standards*
IR	Imposto de Renda
LB	Lucro Bruto
LL	Lucro Líquido
LO	Lucro Operacional
LOGIT	Regressão Logística
Ln	Logaritmo natural
LRF	Lei de Recuperação Judicial e Falência
LSA	Lei das Sociedades por Ações
LTDA	Sociedade Limitada
OCDE	Organização de Cooperação e de Desenvolvimento Econômico
PC	Passivo Circulante
PECLD	Perdas Estimadas em Créditos de Liquidação Duvidosa
PL	Patrimônio Líquido
PNC	Passivo Não Circulante
PRJ	Plano de Recuperação Judicial
PT	Passivo Total
RAE	*Relative Absolute Error*
RJ	Recuperação Judicial
RMSE	*Root Mean Square Error*
RNA	Redes Neurais Artificiais
ROA	*Return on Assets*
ROC	*Receiver Operating Characteristic*

ROE	*Return on Equity*
RRSE	*Root Relative Squared Error*
S/A	Sociedade por Ações
SEBRAE	Serviço Brasileiro de Apoio às Micro e Pequenas Empresas
USGAAP	*United States Generally Accepted Accounting Principles*

SUMÁRIO

1. INTRODUÇÃO 16
1.1. Justificativa e Contribuição 18
1.2. Questão de Pesquisa e Objetivos 19
1.3. Estrutura do Trabalho 21
2. REFERENCIAL TEÓRICO 22
2.1. Literatura relevante e evolução histórica 22
2.2. Falência e recuperação judicial 24
2.3. Recuperação judicial no Brasil 28
2.4. Fatores determinantes da insolvência 32
2.4.1. Modelos teóricos 34
2.4.2. Modelos estatísticos 35
2.4.3. Modelos de inteligência artificial 35
3. MATERIAIS E MÉTODOS 38
3.1. Seleção das variáveis 38
3.2. Determinação da amostra e coleta de dados 44
3.2.1. Estatística descritiva 46
3.3. Modelos utilizados 47
3.3.1. Redes neurais artificiais 49
3.3.2. LOGIT e modelos de regressão 52
4. RESULTADOS E ANÁLISES 54
4.1. Regressão linear e LOGIT 54
4.2. RNA para *output* RJ 57
4.3. RNA para *output* T 60
4.4. Análise e discussões 62
5. CONSIDERAÇÕES FINAIS 67
REFERÊNCIAS 70

1. INTRODUÇÃO

O livre exercício de qualquer atividade econômica, independentemente de autorização de órgãos públicos, ressalvados os casos previstos em lei, é amplamente assegurado pela Constituição Federal de 1988 (CF/88), quando estabelece, em seu artigo 170, que a ordem econômica, fundada na valorização do trabalho humano e na livre iniciativa, tem por fim garantir a todos existência digna, conforme os ditames da justiça social, observando-se, para tanto, os princípios da soberania nacional, propriedade privada, função social da propriedade, livre concorrência, defesa do consumidor e do meio ambiente, redução das desigualdades sociais e regionais, busca do pleno emprego, entre outros e assegurando, ainda, por intermédio do seu parágrafo único, o livre exercício de qualquer atividade econômica, independentemente de autorização de órgãos públicos, ressalvados os casos previstos em lei (Scabora, 2018).

Wennekers e Thurik (1999) sustentam que o empreendedorismo é um dos principais fatores estimulantes do crescimento econômico, apontado por diversos autores como um mecanismo crucial para o desenvolvimento (Stam et al., 2011), pois é através da dinâmica da economia que se dá a livre produção e a circulação de bens e serviços necessária para atendimento dos preceitos constitucionais. Todavia, o desenvolvimento econômico somente desponta quando presentes as condições institucionais adequadas (Boettke & Coyne, 2009).

De acordo com dados do Programa de Indicadores de Empreendedorismo da Organização de Cooperação e de Desenvolvimento Econômico (OCDE), de fato, o sucesso da atividade empresarial não depende apenas do empreendedor, mas, pelo contrário, está sujeito a diversos fatores políticos, jurídicos, sociais, e, principalmente, econômicos. Contudo, se os fatores micro (i.e., oferta e demanda) e macroeconômicos (i.e., juros e inflação) podem contribuir para o crescimento da atividade empresarial, a sua volatilidade impacta diretamente no desempenho das entidades (OCDE, 2017), podendo levar a situações adversas, desde dificuldades econômico-financeiras até mesmo ao estado de insolvência.

Em tempos de crise essas externalidades são potencializadas (Evans & Borders, 2014), o que torna as companhias mais suscetíveis a se tornarem insolventes, isto é, verem-se diante de situação na qual o seu fluxo de caixa não mais é suficiente para fazer frente às suas obrigações financeiras (Wruck, 1990), levando inúmeras empresas a buscarem opções para recuperação da sua estabilidade/equilíbrio econômico-financeira, dentre as quais ganha destaque a recuperação judicial, vista como verdadeira alternativa para a insolvência.

No Brasil, essas alternativas ficam mais claras com a introdução das figuras da falência e da recuperação judicial, a partir da edição da Lei nº. 11.101, de 09 de fevereiro de 2005, também conhecida como Lei de Recuperação Judicial e Falência (LRF).

De acordo com o indicador Serasa Experian de Falências e Recuperações, o número de pedidos de recuperação judicial tem crescido sistematicamente desde a edição da LRF (Serasa, 2018), tendência que se acentuou com a crise mundial de 2008 e tem se reproduzido mundo afora (Evans & Borders, 2014). Ainda de acordo com a pesquisa, os pedidos de recuperação judicial reportados em 2016 representam o maior índice acumulado desde 2006, num intervalo de apenas uma década, quando entrou em vigor a LRF (Serasa, 2018).

Além disso, nos últimos anos, o mercado brasileiro assistiu diversas companhias disputarem o título de maior recuperação judicial do País, respectivamente, com o pedido de recuperação judicial da Óleo e Gás Participações S.A. em 2014 (R$ 12 bilhões), da OAS S.A. em 2015 (R$ 11,5 bilhões) e da Sete Brasil Participações S.A. (R$ 19,3 bilhões), Ecovix Construções Oceânicas S.A. (R$ 8 bilhões) e Oi S.A. (R$ 65,4 bilhões) em 2016 e, finalmente, da Odebrecht S.A. em 2019 (R$ 98,5 bilhões), conforme levantamentos realizados nos processos judiciais das respectivas empresas:

Gráfico 1 – As maiores recuperações judiciais do Brasil (em bilhões de Reais)

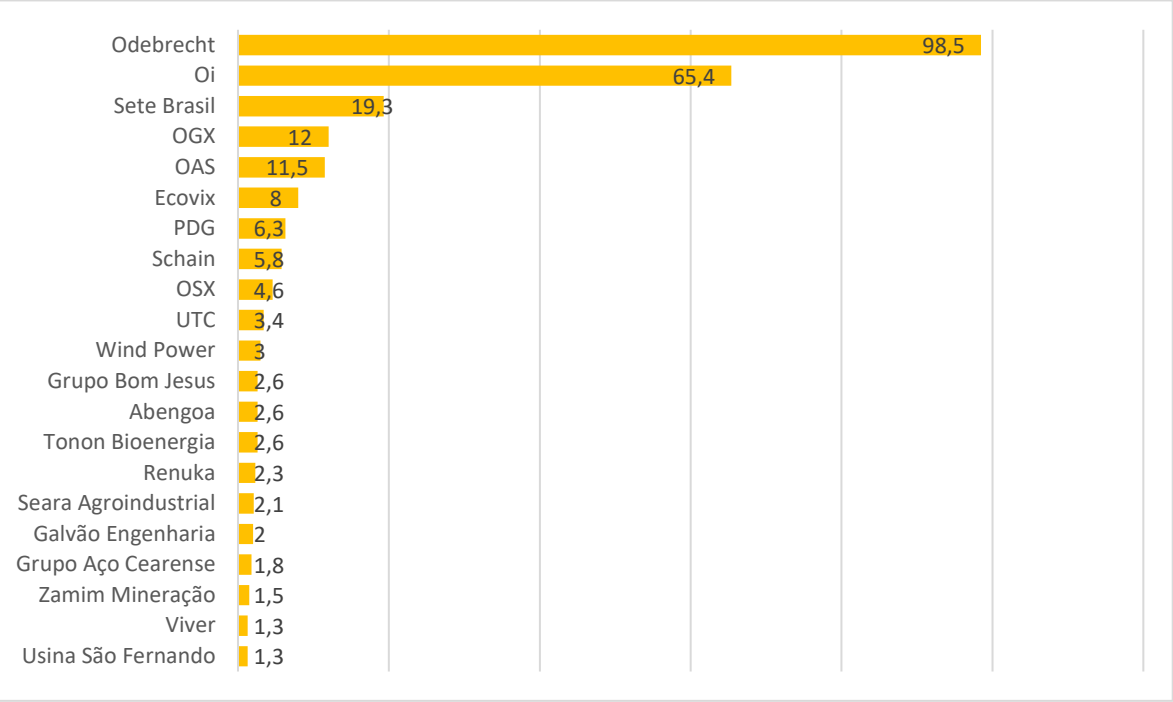

Fonte: elaborado pelo autor

1.1. Justificativa e Contribuição

Apesar desses eventos contemporâneos (crise mundial e investigações criminais) que podem ter contribuído para a sua proliferação, a recuperação judicial e a falência não são problemas recentes (Baird, 1991). Os efeitos deletérios da insolvência das companhias para investidores e credores instigou a proliferação de modelos preditivos, principalmente a partir da década de 1960 (Altman, 1968).

Aziz e Dar (2006) propõe uma classificação tripartite para esses modelos de predição de insolvência, que seriam, então, divididos de acordo com a sua natureza teórica (Crouhy et al., 2000; Lucas, 1995; Aziz et al., 1988), estatística (Altman, 1968, 1984a; Beaver, 1966), e, finalmente, de inteligência artificial (Zhanga et al., 1999; Brockett et al., 1994).

Mais recentemente, Pereira e Martins (2016) se propõe a atualizar a revisão da literatura sobre o tema, apresentando novos componentes comparativos, com enfoque na sua capacidade preditiva e nas variáveis adotadas. O estudo dos autores brasileiros (Pereira & Martins, 2016), apesar de deixar claro o avanço na utilização de modelos de inteligência artificial a partir dos anos 1990 (Yu et al., 2014), demonstra tratar-se de uma abordagem ainda bastante embrionária, mormente no Brasil.

Outro dado interessante apresentado (Pereira & Martins, 2016) diz respeito à seleção das variáveis adotadas, campo em que a predominância de dados/indicadores financeiros e de balanço patrimonial é inconteste, o que também é objeto de crítica por Jardin e Séverin (2011). Para Jones et al. (2017) isso demonstra que, mesmo no campo dominante da estatística (*mainstream*) há evidências (em sentido contrário, vemos Obermann & Waack, 2015) de que os modelos mais modernos teriam melhor performance do que as abordagens tradicionais (Jones et al., 2015), o que inclui não apenas ferramentas estatísticas e de inteligência artificial mais sofisticadas, como também indicadores menos ortodoxos.

Embora Casey e Bartczack (1985) apontem que o fluxo de caixa operacional, de forma isolada, não se destaque enquanto variável de previsão, a combinação de informações contábeis, de mercado e de dados macroeconômicos (Tinoco & Wilson, 2013), tem um papel significativo para explicar a insolvência das organizações dentro de seus ciclos de negócios (Drobetz et al., 2017).

Os fluxos de caixa são variáveis mais sensíveis (Fazzari et al., 1988) à ambientes de (in)solvência nas organizações (Drobetz et al., 2017), razão pela qual podem evidenciar informações relevantes quanto às decisões envolvendo origem, administração e aplicação de

recursos pela entidade (Ohlson & Aier, 2009), constituindo um elemento importante na investigação da solvência das organizações, que merece ser melhor explorado, posto tratar-se mesmo de uma preocupação global (Altman & Narayanan, 1997) para alertar quanto a possíveis novas crises financeiras.

Dotadas de um caráter mais dinâmico e de grande capacidade de auto ajustamento, as Redes Neurais Artificiais (RNA) constituem uma ferramenta de inteligência artificial baseada em simulações matemáticas que reproduzem artificialmente um sistema de raciocínio lógico que se assemelha aos dos neurônios (Haykin, 2008) e são preferencialmente utilizadas em ambientes sujeitos a mutações constantes (Khashei & Bijari, 2010), o que as torna um instrumento bastante apropriado para investigar variáveis mais sensíveis como os fluxos de caixa.

A conjugação desses elementos permite construção de índices e a sua comparação no contínuo, dando consistência às informações coletadas e auxiliando na interpretação dos resultados obtidos (Zhang et al., 1998), e, embora dotados de menor capacidade explicativa, esses dados podem fornecer uma contribuição metodológica importante (Trippi & Lee, 1996) para o estudo da insolvência das organizações.

Ao final, portanto, apresenta-se um modelo de previsão inovador, que, integrando diferentes métodos e indicadores pouco utilizados pela literatura de referência, mormente em relação a dados brasileiros, é capaz de aprimorar a capacidade preditiva da recuperação judicial, em contraste com os modelos atuais, proporcionando soluções gerenciais, de planejamento e de controle (Khashei & Bijari, 2010), com inúmeras aplicações para o mercado e a academia.

1.2. Questão de Pesquisa e Objetivos

Mesmo diante de inúmeras evidências de que a adoção de indicadores não financeiros e métodos alternativos de pesquisa (como a inteligência artificial) têm o potencial de apresentar resultados mais eficazes e promissores (Jones et al, 2017; Jones et al, 2015), a pouca concentração da aplicação de métodos de inteligência artificial é apontada por inúmeros autores, como Aziz e Dar (2006), Yu et al. (2014) e Pereira e Martins (2016).

Considerando apenas os dados brasileiros apresentados por Pereira e Martins (2016), voltados para as empresas nacionais, são poucos os estudos nesse campo que vão além dos

modelos estatísticos ortodoxos, e, quando conjugados à adoção de variáveis outras que não simplesmente os indicadores financeiros, a pesquisa em previsão de insolvência no país encontra-se estagnada.

As pesquisas em previsão de insolvência no Brasil também têm se limitado em razão da ausência de uma caracterização precisa do evento preditivo que pretendem ver analisado (insolvência). Isso porque a legislação brasileira (LRF) estabelece uma distinção precisa entre os procedimentos de recuperação judicial e falência, que não é necessariamente encontrada em outros países, e pode mesmo representar um distanciamento temporal significativo.

Em sua grande maioria, os estudos sobre o tema no País estão circunscritos, desde o início (Elizabetsky, 1976; Kanitz, 1978; Matias, 1978), a observar a capacidade preditiva de modelos até o ponto da insolvência técnica (*technical insolvency* – Figura 1) ou da falência, não demonstrando grandes preocupações em segregar a recuperação judicial como evento digno de nota.

A ausência dessa distinção é relevante, principalmente se considerarmos a existência de casos, no Brasil, em que o pedido de recuperação judicial e a decretação de falência estão separados por mais de uma década.

Diante disso é que se apresentam as questões de pesquisa deste trabalho: **quais os fatores determinantes da recuperação judicial considerando os fluxos de caixa das firmas evidenciados na Demonstração de Fluxo de Caixa (DFC)**? E, adicionalmente: **o método de RNA apresenta melhores resultados do que a regressão logística (LOGIT) para a previsão da recuperação judicial?**

Para responder a esses questionamentos, objetiva-se identificar – principalmente através da seleção de variáveis e métodos alternativos – um modelo preditivo mais acurado do que os atuais.

Além disso, outro objetivo específico importante da pesquisa encontra-se na definição do evento que se pretende ver analisado: enquanto a maioria dos autores prende-se à figura da falência ou da insolvência, o evento de interesse neste trabalho será o pedido de recuperação judicial, que antecede a falência na LRF – e pode, ou não, antecipar-se à insolvência –, posto se tratar do momento em que, legalmente, o devedor poderá buscar, através de um plano de reorganização da empresa, a renegociação forçada do seu crédito, com efeitos adversos para os *stakeholders*.

1.3. Estrutura do Trabalho

Para investigar a existência de relação entre os fluxos de caixa das firmas e a recuperação judicial, primeiramente, no Capítulo 1 – Introdução, será apresentado e contextualizado o problema de pesquisa e seus objetivos, evidenciando-se a sua relevância e contribuição para a área de conhecimento.

No Capítulo 2 – Referencial Teórico, serão apresentadas as principais linhas de pesquisa em previsão de insolvência das organizações, demonstrando a sua evolução por meio de um componente histórico cronológico, que envolve não apenas a utilização (ou não) de métodos estatísticos mais sofisticados, mas também a seleção de variáveis.

Também neste capítulo, serão abordados os diferentes conceitos de insolvência e como se inter-relacionam com os institutos da recuperação judicial e da falência, instituídos pela legislação brasileira, bem como os seus efeitos para os *stakeholders*, além de ilustrar o panorama geral das recuperações judiciais no Brasil.

O Capítulo 3, intitulado Materiais e Métodos, compreende o detalhamento dos critérios utilizados na determinação da amostra e do recorte temporal dos dados que serão analisados. Além disso, também contém o as explicações em torno da natureza da amostra e da coleta e formatação da base de dados, juntamente com a seleção das variáveis a partir da literatura de referência e o modelo proposto.

No Capítulo 4 – Resultados e Análises, serão apresentados os resultados obtidos a partir do modelo proposto, assim como a sua interpretação, relacionando-os com a questão de pesquisa e a literatura técnica especializada, a fim de debater sua eficácia.

Por fim, o Capítulo 5 – Considerações Finais, apresentará as articulações e limitações deste estudo, bem como as novas oportunidades de pesquisa que sobrevirão dos resultados obtidos.

2. REFERENCIAL TEÓRICO

2.1. Literatura relevante e evolução histórica

A recuperação judicial e a falência não são problemas recentes – sua origem pode ser situada no século XVIII, com a Constituição dos Estados Unidos da América de 1789 que atribui aos congressistas os poderes necessários para promulgar leis tratando da falência (Baird, 1991). O grande impacto desses eventos para o ambiente corporativo instigou, ao longo dos anos, um volume significativo de análises e modelos preditivos, principalmente a partir da década de 1960, com os trabalhos seminais de Altman (1968) e Beaver (1966).

Aziz e Dar (2006) propõe uma classificação tripartite para esses modelos de predição, que seriam, então, divididos em três categorias, conforme Tabela 1 abaixo:

Tabela 1 - Classificação dos modelos de previsão de insolvência

Classificação Modelo	Características
Modelos teóricos	Focam nas causas qualitativas da falência Modelados a partir de informações que possam satisfazer o argumento teórico da falência proposto pela teoria Natureza multivariada Normalmente empregam técnicas estatísticas para fornecer suporte quantitativo para o argumento teórico
Modelos estatísticos	Focam nos sintomas da falência Modelados a partir de informações contábeis da companhia Podem ser de natureza univariada ou multivariada (mais comum) Seguem os padrões clássicos de modelagem
Modelos de inteligência artificial	Focam nos sintomas da falência Modelados a partir de informações contábeis da companhia Normalmente de natureza multivariada Resultado do avanço tecnológico e do desenvolvimento informacional Altamente dependentes de tecnologia computacional

Fonte: adaptado de Aziz e Dar (2006, p. 19)

De acordo com a classificação proposta, os modelos de previsão de insolvência seriam, então:

(i) teóricos (Crouhy et al., 2000; Lucas, 1995; Aziz et al., 1988), voltados à explicação teórica da falência utilizando dados obtidos, inclusive, por meio de

técnicas estatísticas, geralmente de análise multivariada, para fornecer elementos qualitativos que deem suporte à teoria adotada;

(ii) estatísticos (Altman, 1968; Beaver, 1966), com foco nos sintomas da falência, utilizam dados obtidos a partir das informações contábeis das organizações, por meio de análise univariada ou multivariada, considerados o *mainstream* dos modelos de previsão de insolvência; e, finalmente,

(iii) de inteligência artificial (Zhanga et al., 1999; Brockett et al., 1994), também focados nos sintomas da falência, mas com um elemento tecnológico que faltava aos modelos puramente estatísticos, geralmente através de análises multivariadas em relação às informações contábeis das organizações.

O componente histórico-cronológico dessa classificação é reforçado, entre outros, por Pereira e Martins (2016) e Kumar e Ravi (2007), quando evidenciam o processo evolutivo das pesquisas na área, partindo dos trabalhos originais de Fitzpatrick (1932), passando por Altman (1968, 1984a, 1984b), até os estudos mais recentes envolvendo inteligência artificial e *machine learning* (como Azayite & Achchab, 2016; Wang et al., 2017; Barboza et al., 2017).

Um panorama interessante sobre a acuidade desses modelos de previsão é apresentado por Jardin (2017), que traça um paralelo entre os principais trabalhos na área e o modelo conceitual adotado (teórico, estatístico ou de inteligência artificial).

A eficiência dos modelos de previsão também é abordada por Pereira e Martins (2016); os autores inovam ao conjugar informações relevantes acerca dos indicadores (como Jones et al., 2017), modelos de previsão, eficácia e cronologia utilizados, oferecendo um retrato significativo dos trabalhos realizados a partir da década de 1970 até os dias atuais. A comparação entre os modelos de previsão também é alvo de Aziz e Dar (2006), ainda que, nesse caso, limitando-se a evidenciar a preferência pelos modelos adotados pelos pesquisadores.

Nada obstante o avanço na utilização de modelos de inteligência artificial a partir dos anos 1990 apontada por diversos autores (Yu et al., 2014), as conclusões apresentadas por Pereira e Martins (2016) e Aziz e Dar (2006) são semelhantes, ao indicarem tratar-se de uma abordagem ainda embrionária, apresentando pouca representatividade em comparação com os demais trabalhos na área, que enfatizam os modelos estatísticos e teóricos, nessa ordem.

Jardin e Séverin (2011) criticam os modelos teóricos e estatísticos adotados, não apenas em razão da abordagem quanto ao período de coleta de dados (que eles chamam de *single-period models*), mas também ressaltam que tais modelos têm se tornado fonte de inúmeras críticas quanto à forma como as variáveis são selecionadas, a influências de fatores exógenos e a própria eficácia da previsão.

O lento processo de evolução dos modelos de previsão também é criticado por Jones et al. (2017). Para os autores, mesmo no campo da estatística os modelos de previsão de falência têm deixado de explorar inovações que poderiam trazer resultados interessantes, havendo evidências (não unânimes, como vemos em Obermann & Waack, 2015) de que os modelos mais modernos podem suplantar significativamente a performance das abordagens mais tradicionais (Jones et al., 2015; Jones, 2017).

Com efeito, Pereira e Martins (2016) apontam pouca concentração da aplicação de métodos de inteligência artificial para dados brasileiros e mesmo as pesquisas existentes enfatizam a adoção de indicadores financeiros mensurados ao longo de um intervalo de tempo para criação de um modelo estatístico (Jones et al., 2017).

2.2. Falência e recuperação judicial

A CF/88 estabelece a ordem econômica, fundada na valorização do trabalho humano e na livre iniciativa, todavia, garantir o livre exercício de qualquer atividade econômica não é suficiente se não se fizerem presentes condições institucionais adequadas para assegurar o desenvolvimento econômico (Boettke & Coyne, 2009). Dados do Programa de Indicadores de Empreendedorismo da OCDE evidenciam que o sucesso da atividade empresarial está ligado a diversos fatores políticos, jurídicos, sociais, e, principalmente, econômicos, o que parece corroborar a alegação que a empresa é essencial para o crescimento econômico (Wennekers & Thurik, 1999; Stam et al., 2011).

Admitindo-se que fatores micro e macroeconômicos estão ligados ao bom desenvolvimento da atividade empresarial, em tempos de crise aumenta a busca de opções para recuperação da estabilidade/equilíbrio econômico-financeira (James, 2012), dentre as quais ganha destaque a recuperação judicial, vista como verdadeira alternativa para a insolvência.

Wruck (1990) define a insolvência como o momento em que o fluxo de caixa da entidade não mais é suficiente para fazer frente às suas obrigações financeiras. Ainda de

acordo com o autor, essa condição pode ser temporária, no que se costuma denominar de *technical insolvency* ou *flow-based insolvency* (insolvência técnica), caracterizado pelo período ou momento em que o caixa da organização deixa de ser suficiente para adimplemento das suas obrigações, ou de caráter perene (*stock-based insolvency*).

Figura 1 – Insolvência técnica e insolvência baseada em saldo

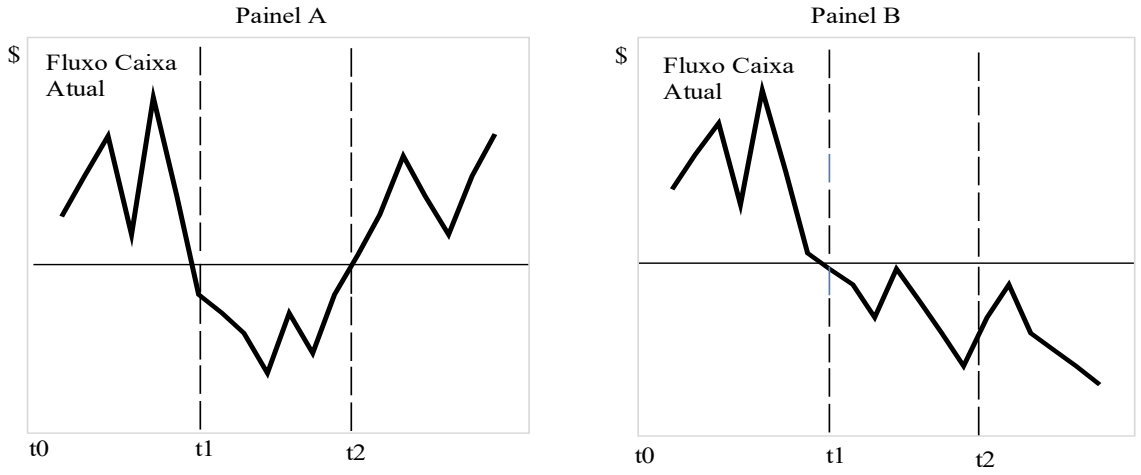

Fonte: adaptado de Wruck (1990)

A Figura 1 representa graficamente as diferenças entre a insolvência técnica (Painel A) e a insolvência baseada em saldo (Painel B) evidenciando claramente a natureza (temporária ou perene) desses eventos. Embora para Altman (1983) a insolvência baseada em saldo seja mais preocupante, pois indica uma condição crônica da organização, caracterizada, principalmente, pela presença de patrimônio líquido negativo, Wruck (1990) esclarece que, do ponto de vista dos credores, a insolvência técnica é o evento mais apropriado para indicar a necessidade de reestruturação das organizações, pois demarca o momento em que os contratos deixam de ser cumpridos.

No Brasil, até a edição da LRF, a incapacidade da firma em seguir horando seus contratos tinha como resultados possíveis a falência ou a concordata, ambas, então, reguladas pelo Decreto-Lei (DL) nº. 7.661, de 21 de junho de 1945. De acordo com o artigo 1º do DL "*considera-se falido o comerciante que, sem relevante razão de direito, não paga no vencimento obrigação líquida, constante de título que legitime a ação executiva*".

A falência poderia ser requerida pelos credores ou pelo próprio devedor, operando-se por meio da liquidação dos ativos da organização para adimplemento das obrigações assumidas, cessando as suas atividades, enquanto a concordata constituía uma espécie de moratória judicial requerida pelo devedor, que desobrigava o pagamento dos seus créditos por um determinado período, vedando a expropriação de bens para exigência das dívidas existentes.

No regime do DL "*a concordata é preventiva ou suspensiva, conforme fôr pedida em juízo antes ou depois da declaração da falência*" (art. 139) e, quando preventiva, autorizava o devedor a buscar, junto aos credores, descontos para pagamento das dívidas inadimplidas (art. 156).

Embora a concordata assegurasse ao devedor uma suspensão temporária no adimplemento de suas obrigações, que podiam mesmo ser renegociadas com os credores, o instituto, como o próprio DL deixa claro, tinha por objetivo principal evitar a decretação da falência e a consequente extinção da empresa, ainda que, na prática, pudesse funcionar como um mecanismo para garantir a continuidade da empresa em situações de insolvência.

Somente com o advento da LRF, em 09 de fevereiro de 2005, introduziu-se, na legislação brasileira, um instituto jurídico moldado para assegurar a reestruturação econômico-financeira das organizações envoltas em problemas de insolvência.

A chamada recuperação judicial, prevista no artigo 47 da LRF "*tem por objetivo viabilizar a superação da situação de crise econômico-financeira do devedor, a fim de permitir a manutenção da fonte produtora, do emprego dos trabalhadores e dos interesses dos credores, promovendo, assim, a preservação da empresa, sua função social e o estímulo à atividade econômica*".

O dispositivo legal em referência cristalizou, na legislação brasileira, o que se costumou chamar de "princípio da preservação da empresa", valor básico que, objetivando a manutenção da atividade econômica e a função social da organização, assegura, sob determinadas condições legal e contratualmente estabelecidas, a concessão de estímulos para recuperação econômico-financeira da empresa.

Figura 2 - Fluxograma simplificado da recuperação judicial

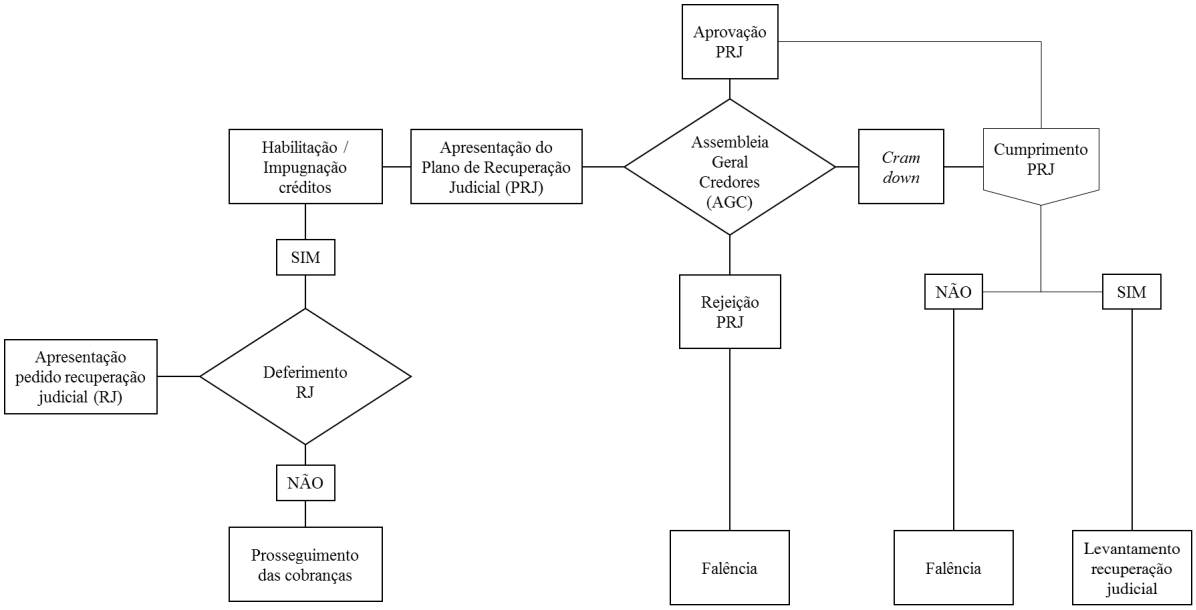

Fonte: elaborado pelo autor

A Figura 2 contém uma representação simplificada dos procedimentos estabelecidos pela LRF, dentre os quais podemos destacar, por relevância:

(i) a apresentação do pedido, momento em que a organização deve submeter ao juízo, entre outros, "*a exposição das causas concretas da situação patrimonial do devedor e das razões da crise econômico-financeira*" (art. 51 da LRF);

(ii) o deferimento do pedido, oportunidade em que o juiz, em sede de cognição sumária, reconhece a situação de crise experimentada pela organização e suspende todas as cobranças contra a organização pelo prazo máximo de "*180 (cento e oitenta), contado do deferimento do processamento da recuperaçã*o" (art. 6º, §4º da LRF);

(iii) a apresentação do Plano de Recuperação Judicial (PRJ), no qual a organização detalhará aos credores as condições para recuperação econômico-financeira da empresa e pagamentos dos seus créditos, que podem incluir a "*concessão de prazos e condições especiais para pagamento das obrigações vencidas ou vincendas*", entre outras (art. 50 da LRF);

(iv) a realização da Assembleia Geral de Credores (AGC) para discussão do PRJ pelos credores, donde resulta uma das três situações a seguir: (a) a aprovação do PRJ, com a concessão e prosseguimento da recuperação judicial até o seu integral cumprimento; (b) a rejeição do PRJ, com a decretação da falência; e, (c) a aprovação do PRJ sem o quórum legal necessário, hipótese em que caberá ao juiz decidir se defere a concessão da recuperação judicial (*cram down*) ou decreta a falência da empresa (art. 58 da LRF); e, finalmente,

(v) o cumprimento do PRJ, cuja não observação pela organização, poderá resultar na decretação da falência, mesmo após a concessão da recuperação judicial.

O que se verifica é que a recuperação judicial funciona como uma alternativa para evitar a falência das organizações, através da implementação de um plano para reorganização das dívidas da empresa que, ao final permita-lhe abandonar a condição de insolvente.

2.3. Recuperação judicial no Brasil

A finalidade de preservar e garantir a manutenção da empresa – que diferencia primordialmente a recuperação judicial da figura da antiga concordata e da falência – estimulou a proliferação dos requerimentos de recuperação judicial no País. De acordo com o indicador Serasa Experian de Falências e Recuperações (Serasa, 2018), o número de pedidos de recuperação judicial mais do que dobrou apenas no primeiro trimestre do ano-calendário de 2018, saltando de 191 ocorrências entre os meses de janeiro a março do ano-calendário 2015 para 385 ocorrências em comparação com o mesmo período do ano-calendário de 2018.

Tabela 2 - Falências, recuperações judiciais e concordatas

Ano	Falência	Recup. Judicial	Concordata
1991	1.132	-	738
1992	2.289	-	767
1993	2.644	-	470
1994	2.532	-	628
1995	3.142	-	2.359
1996	6.043	-	1.072

continua

conclusão

Ano	Falência	Recup. Judicial	Concordata
1997	6.508	-	552
1998	6.156	-	736
1999	6.266	-	463
2000	4.909	-	221
2001	3.810	-	282
2002	4.774	-	276
2003	4.389	-	270
2004	3.497	-	156
2005	2.876	110	83
2006	1.977	252	-
2007	1.479	269	-
2008	969	312	-
2009	908	670	-
2010	732	475	-
2011	641	515	-
2012	688	757	-
2013	746	874	-
2014	740	828	-
2015	829	1.287	-
2016	721	1.863	-
2017	928	1.420	-
2018	234	385	-
Total	72.559	10.017	9.073

Fonte: elaborado pelo autor a partir dos dados do Serasa (2018)

A Tabela 2 indicada o número de falências decretadas e recuperações judiciais e concordatas requeridas entre janeiro de 1991 e março de 2018, no país. Num intervalo de quase 15 anos, de janeiro de 1991 até junho de 2005, quando entrou em vigor a LRF, 9.073 empresas brasileiras apresentaram pedidos de concordata, contra 10.017 pedidos de recuperação judicial em pouco mais de uma década de vigência da LRF (entre junho de 2005 e março de 2018), um crescimento médio de cerca de 25% no número de pedidos de recuperação judicial, conforme Tabela 3 abaixo:

Tabela 3 - Pedidos de concordata e recuperação

	Nº Pedidos	Meses	Média	Variação
Concordata	9.073	174	52	24,74%
Recuperação Judicial	10.017	154	65	

Fonte: elaborado pelo autor a partir dos dados do Serasa (2018)

Ainda de acordo com a pesquisa, o resultado é recorde, representando o maior índice acumulado desde 2006, quando entrou em vigor a LRF. Para Evans e Borders (2014), o crescimento no número de empresas buscando alternativas à insolvência é um fenômeno mundial, que pode ser observado também a partir dos dados brasileiros:

Gráfico 2 - Evolução dos pedidos de recuperação judicial no Brasil

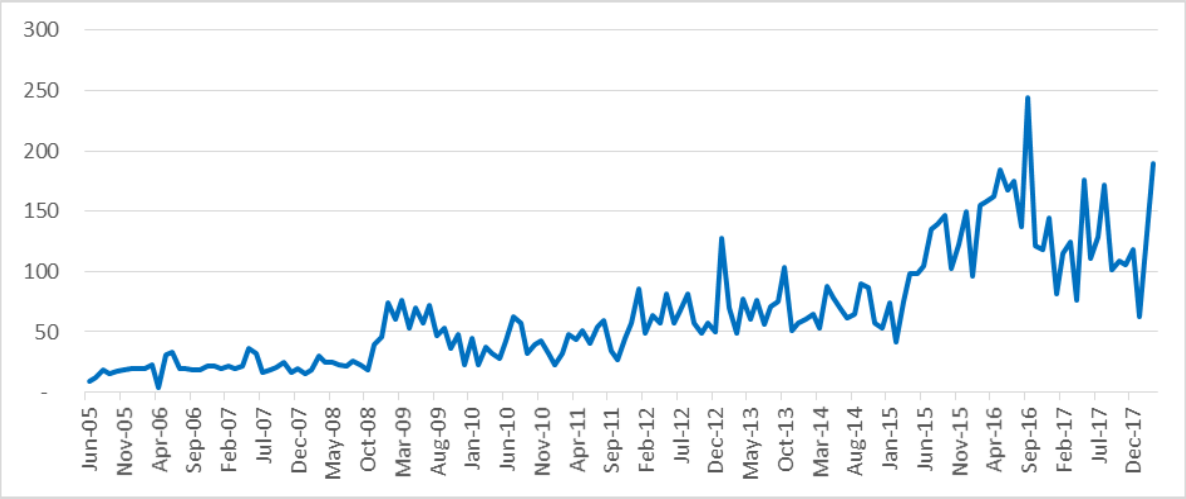

Fonte: elaborado pelo autor a partir dos dados do Serasa (2018)

O Gráfico 2 apresenta a evolução do número de pedidos de recuperação judicial no País desde a entrada em vigor da LRF, demonstrando o crescimento acentuando na ocorrência dos pedidos, principalmente nos períodos que coincidem com a crise econômica mundial de 2008 e o avanço das investigações locais contra a corrupção, no âmbito da Operação Lava-Jato, da Polícia Federal e do MPF.

Gráfico 3 - Evolução dos pedidos de concordata no Brasil

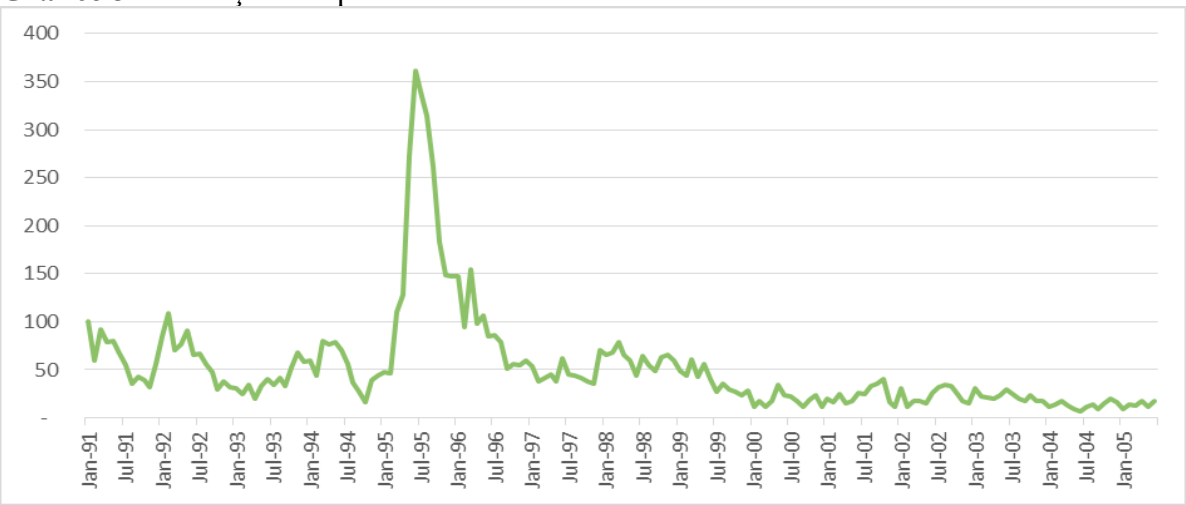

Fonte: elaborado pelo autor a partir dos dados do Serasa (2018)

Já a análise da evolução dos pedidos de concordata na vigência do DL, apresenta distribuição mais homogênea no Gráfico 3.

Gráfico 4 - Falências, recuperações judiciais e concordatas

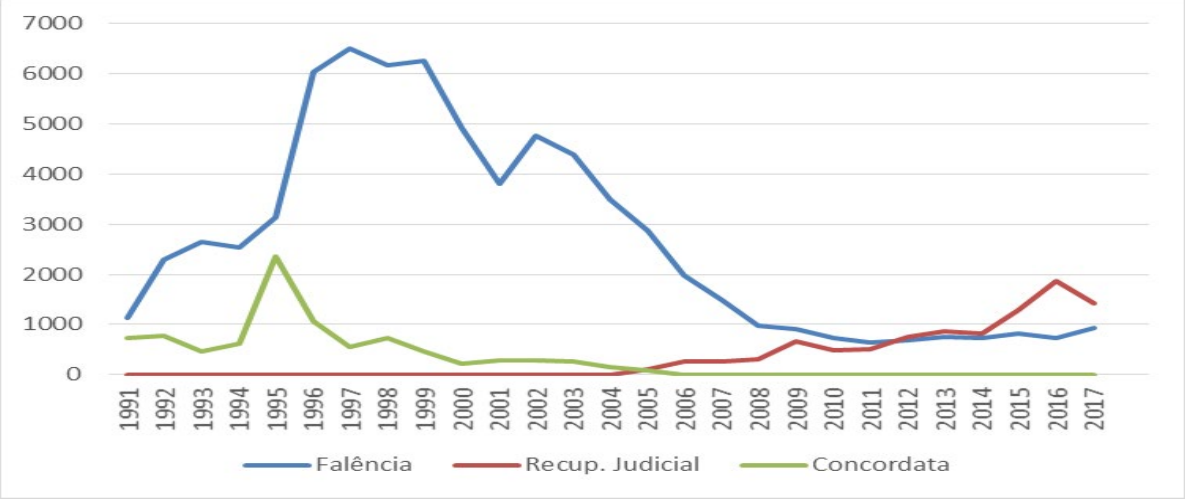

Fonte: elaborado pelo autor a partir dos dados do Serasa (2018)

Por fim, ao confrontar-se o número de falências decretadas e recuperações judiciais e concordatas requeridas no mesmo período (Gráfico 4), algumas observações tornam-se evidentes:

(i) durante a vigência do DL, o número de falências de empresas brasileiras decretadas se manteve em patamares significativamente mais elevados, em contraste com o período de vigência da LRF;

(ii) o número de pedidos de recuperação judicial apresenta uma curva ascendente desde a entrada em vigor do instituto, ultrapassando o número de pedidos de concordata, anteriormente apresentadas num menor espaço de tempo; e,

(iii) em pouco tempo desde a LRF, o número de pedidos de recuperação judicial excedeu o número de falências de empresas brasileiras decretadas, que tem variado de maneira uniforme, sempre em volume inferior às recuperações judiciais.

Tais conclusões reforçam as evidências de que o instituto da recuperação judicial tem se firmado como alternativa viável para superação de situações de insolvência pelas organizações em razão, principalmente, do objetivo declarado de preservação da empresa e manutenção da atividade econômica, que não se atribuía à figura da concordata no regime anterior.

2.4. Fatores determinantes da insolvência

O estudo de falências e recuperações do Serasa Experian (2018) é construído a partir do levantamento mensal das estatísticas de falências (requeridas e decretadas) e das recuperações judiciais e extrajudiciais registradas mensalmente na sua base de dados, provenientes dos fóruns, varas de falências e dos Diários Oficiais e da Justiça dos Estados.

Para os economistas responsáveis pelo levantamento, o baixo dinamismo econômico somado a expressiva queda no consumo das famílias, determinada pela escalada do desemprego e da inflação, e as altas taxas de juros impactaram negativamente a atividade dos setores comercial, industrial e de serviços com reflexos diretos na saúde financeira das empresas (Serasa, 2018), provocando um crescimento acentuado nos pedidos de recuperação judicial.

Todavia, se por um lado a situação da economia exerce influência significativa no desempenho das empresas, de outra ponta, não se pode olvidar também os efeitos da (má) administração. Para a realização de uma administração satisfatória é imprescindível a análise de informações contábeis para que sejam tomadas ações pertinentes que promovam a continuidade ou a evolução dos empreendimentos. Essas informações são apresentadas através de relatórios gerenciais de competência dos profissionais da contabilidade, que levantam o comportamento do mercado e do desempenho interno da empresa, dentre os quais podemos destacar, entre outros, a DFC.

Tomando-se por referência a figura da recuperação judicial, não é difícil imaginar que a situação de insolvência que leva à companhia a ingressar com o pedido de recuperação seja, portanto, também influenciada pela má aplicação dos recursos gerados e/ou obtidos no desempenho da atividade econômica, hipótese que, inclusive, é referendada pela doutrina mais especializada. Com efeito, ao tratar dos fundamentos da recuperação judicial, Teixeira (2012) esclarece que a crise de uma atividade econômica – assim entendida como o conjunto de

fatores que leva uma companhia a buscar a recuperação judicial – pode ocorrer por várias razões: má gestão, escassez de insumos, eventos da natureza, como estiagem ou excesso de chuvas, modificações nas curvas de oferta e de demanda, crises econômicas mundiais ou regionais etc.

Em outras palavras, evidencia-se a influência dos fatores macroeconômicos (Aysun, 2014) e microeconômicos (Alessandria et al., 2015) nos ciclos de negócios e na solvência das firmas. Ciclos de negócios são as flutuações na atividade econômica num dado intervalo de tempo, em que se sucedem períodos de expansão, recessão e crise, influenciados por acontecimentos macro ou microeconômicos (Férnandez, Grohé & Uribe, 2017).

Para Teixeira (2012), os eventos de crise verificados nos ciclos de negócios das organizações podem ser de origem econômica, financeira ou patrimonial. Crise econômica ocorre quando as vendas dos produtos ou a prestação de serviços não são realizadas em quantidade suficiente à manutenção do negócio. A crise financeira acontece quando o empresário tem falta de fluxo de caixa, dinheiro ou recursos disponíveis para pagar suas prestações obrigacionais. Já a crise patrimonial se faz sentir quando o ativo do empresário é menor do que o seu passivo, logo, seus débitos superam os seus bens e direitos (Teixeira, 2012).

A classificação proposta por Teixeira (2012) para as crises da organização não é diferente dos conceitos de insolvência técnica (*technical insolvency*) e insolvência baseada em fluxos (*stock-based insolvency*) apresentados por Wruck (1990) e Altman (1983), evidenciando, portanto, que na opinião desses autores, os eventos de crise que levam as empresas à recuperação judicial tem em comum um aspecto relevante no que diz respeito a capacidade da organização em gerar recursos (receitas) e a administrar a sua alocação, refletida nos seus fluxos de caixa. Robinson e Sensoy (2016) reforçam essas evidências, apontando a existência de uma relação entre o movimento dos fluxos de caixa em situações de expansão, recessão e crise e a performance da entidade (*cash flow sensitivity*).

Os fluxos de caixa, portanto, são sensíveis às decisões de investimento e capacidade de adimplemento das organizações (Fazzari et al., 1988; Drobetz et al., 2017) e essas informações – de investimento, performance e adimplemento de obrigações – são apresentadas através de relatórios gerenciais de competência dos profissionais da contabilidade, que levantam o comportamento do mercado e do desempenho interno da empresa, dentre os quais podemos destacar, entre outros, a DFC.

De acordo com a Lei nº. 6.404, de 15 de dezembro de 1976, também chamada de Lei das Sociedades por Ações (LSA) e os pronunciamentos contábeis em vigor, a DFC deve

evidenciar no mínimo três fluxos financeiros, quais sejam: (i) das operações; (ii) dos investimentos; e, (iii) dos financiamentos.

O Pronunciamento Técnico nº. 03, do Comitê de Pronunciamentos Contábeis (CPC), aprovado pela Deliberação nº. 641, de 07 de outubro de 2010 da Comissão de Valores Mobiliários (CVM) para as companhias de capital aberto, sustenta que as informações sobre o fluxo de caixa de uma entidade são úteis para proporcionar aos usuários das demonstrações contábeis uma base para avaliar a capacidade de a entidade gerar caixa e equivalentes de caixa, bem como as necessidades da entidade de utilização desses fluxos de caixa. Govindarajan (1980), ao tratar dos objetivos das demonstrações financeiras, também sustenta essa hipótese, fazendo referência aos pronunciamentos originais do *Financial Accounting Standards Board* (FASB), com a redação atualizada pelo *Statement of Financial Accounting Concepts* nº. 01:

> *Financial reporting should provide information about how an enterprise obtains and spends cash, about its borrowing and repayment of borrowing, about its capital transactions, including cash dividends and other distributions of enterprise resources to owners, and about other factors that may affect an enterprise's liquidity or solvency* (FASB, 2008)

Portanto, a análise das DFC permite avaliar o comportamento dos fluxos de caixa das empresas ao longo do tempo, na medida em que evidencia as decisões quanto à origem, administração e aplicação de recursos (Ohlson & Aier, 2009), sendo possível buscar relações entre os fluxos financeiros evidenciados e o fato de as entidades buscarem a recuperação judicial como alternativa para a insolvência, muito embora os indicadores de fluxo de caixa não figurem entre as medidas mais utilizadas pela literatura nos modelos de previsão de insolvência.

2.4.1. Modelos teóricos

De acordo com a classificação adotada, voltam-se à explicação teórica da falência (causas qualitativas), inclusive por meio da utilização de ferramentas estatísticas modeladas a partir de informações preparadas para fornecer suporte quantitativo para o argumento teórico do modelo, dentre os quais destacam-se os trabalhos de Theil (1969), Aziz et al. (1988) e Lucas (1995), tendo como principais indicadores o fluxo de caixa operacional e as relações

entre ativo (circulante e não circulante) e passivo (longo e curto prazo) e outros componentes geralmente extraídos das demonstrações contábeis das organizações, principalmente, o BP.

2.4.2. Modelos estatísticos

Se o início da pesquisa em previsão de insolvência pode ser creditado a Fitzpatrick (1932), é com os trabalhos de Altman (1968) e Beaver (1966) que ganhou projeção. O modelo adotado pelos autores – enfatizando os sintomas da falência a partir da análise discriminante em informações contábeis das organizações – viria a se tornar a parte integrante do *mainstream* das pesquisas na área, influenciando fortemente os autores da sua geração, inclusive no Brasil.

Com efeito, os trabalhos de Elizabetsky (1976), Kanitz (1978) e Matias (1978) basearam-se no modelo de Altman (1968), aplicado a dados brasileiros, tendo como principais variáveis de BP e DRE as relações entre ativo (circulante e não circulante), passivo (longo e curto prazo), patrimônio líquido e resultado.

2.4.3. Modelos de inteligência artificial

Também focados nos sintomas da falência, mas com um elemento tecnológico que faltava aos modelos clássicos (estatísticos). Uma vez que os resultados dependem do avanço tecnológico e da evolução do conteúdo informacional, os modelos de inteligência artificial têm conotação mais recente, do início da década de 1990, entre outros, com a utilização de RNA por Zhanga et al. (1999) e Brockett et al. (1994) e, mais recentemente, *machine learning* (Azayite & Achchab, 2016; Wang et al., 2017; Barboza et al., 2017; Jones et al. 2017).

A seleção das variáveis também se diferencia dos demais modelos na medida em que, além dos indicadores financeiros de BP e DRE (elementos de ativo, passivo, patrimônio líquido e resultado), utiliza outras informações extraídas das demonstrações contábeis das organizações, como a DFC, e também dados macro e microeconômicos (setor, idade, participação de mercado e inflação, dentre outros).

Tabela 4 - Principais modelos de previsão de insolvência e suas variáveis

Classific.	Modelagem	Variáveis	Fórmula	Autor
Teóricos	Análise discriminante	FCO	Fluxo de Caixa Operacional	Aziz (1988)
		Disponível	Disponível	
		AC	AC	
		PCP	Passivo Curto Prazo	
		PMP	Passivo Médio Prazo	
		CS	CS	
		PNC	PNC	
		IR	IR pago	
	Correlação Estatística	Insolvência	*Default index anual*	Lucas (1995)
		Dummy	Solvente ou insolvente	
Estatísticos	Análise discriminante	Capital de giro líquido (CGL)	(AC - PC) / AT	Altman (1968)
		Lucros Retidos sobre AT	Lucros Retidos / AT	
		EBIT sobre AT	EBIT / AT	
		Giro do Ativo	Vendas / AT	
		Valor mercado ações sobre PT	Valor mercado ações / PT	
	Análise discriminante e análise de correlação linear	Margem Líquida	LL / Vendas	Elizabetsky (1976)
		Disponível sobre AP	Disponível / AP	
		Contas a receber sobre AT	Contas a receber / AT	
		Estoques sobre AT	Estoques / AT	
		PC sobre AT	PC / AT	
	Regressão múltipla e análise discriminante	Retorno sobre PL (ROE)	LL / PL	Kanitz (1978)
		Liquidez Geral	(AC + ARLP) / PT	
		Liquidez Seca	(AC - estoques) / PC	
		Liquidez Corrente	AC / PC	
		Endividamento Total	PT / PL	
	Análise discriminante	PL sobre AT	PL / AT	Matias (1978)
		Passivo Financeiro sobre AC	Passivo financeiro / AC	
		Fornecedores sobre AT	Fornecedores / AT	
		Liquidez Corrente	AC / PC	
		LO sobre LB	LO / LB	
		Disponível sobre AT	Disponível / AT	
Inteligência artificial	*Hybrid Discriminant Neural Networks*	CG sobre AT	CG / AT	Azayite e Achchab (2016)
		Lucros Retidos sobre AT	Lucros Retidos / AT	
		EBIT sobre AT	EBIT / AT	
		Valor mercado ações sobre PT	Valor mercado ações / PT	
		Giro do Ativo	Vendas / AT	
	Grey wolf optimization	Liquidez imediata	Disponível / PC	Wang et al (2017)
		Disponível sobre AT	Disponível / AT	
		Liquidez Corrente	AC / PC	
		AC sobre AT	AC /AT	
		CG sobre AT	CG / AT	
		CG sobre Vendas	CG / Vendas	
		Giro estoques	Vendas / Estoques	
		Giro contas a receber	Vendas / contas a receber	
		ROA	LL / AT	
		LL sobre AC	LL / AC	
		Margem Líquida	LL / Vendas	
		Margem Bruta	LB / Vendas	
		LL sobre PT	LL / PT	
		ROE	LL / PL	
		LL sobre PNC e PL	LL / (PNC + PL)	
		Vendas sobre AC	Vendas / AC	
		Giro do Ativo	Vendas / AT	
		Contas a receber sobre PT	Contas a receber / PT	
		Grau endividamento	PT / AT	
		Endividamento total	PT / PL	

Fonte: elaborado pelo autor

A Tabela 4 apresenta um panorama resumido dos principais modelagens e variáveis adotadas por alguns dos autores abordados nesta pesquisa, selecionados de acordo com a classificação proposta para os seus modelos de previsão de insolvência (teóricos, estatísticos e de inteligência artificial), evidenciando claramente a similitude dos principais modelos estatísticos em termos de análise e seleção de variáveis, em contraste com os modelos mais recentes de inteligência artificial.

3. MATERIAIS E MÉTODOS

3.1. Seleção das variáveis

Embora a existência de relação entre as situações de insolvência – que levam as companhias a ingressarem com pedido de recuperação judicial – e a aplicação dos recursos gerados e/ou obtidos no desempenho da atividade econômica seja evidenciada por inúmeros autores, como visto, a utilização de indicadores financeiros extraídos do BP e da DRE tem grande prevalência nos estudos e modelos de previsão de falência (Jones et al., 2017).

O levantamento de Pereira e Martins (2016) aponta que os indicadores envolvendo fluxos de caixa não se encontram entre as principais variáveis utilizadas em estudos internacionais e a frequência para dados brasileiros é ainda mais insignificante.

Tabela 5 - Frequência dos indicadores envolvendo fluxo de caixa

Indicadores financeiros utilizados na previsão de falência	Frequência estudos internacionais	Frequência estudos nacionais	Total
Lucro Líquido / Total do Ativo	94	16	110
Ativo Circulante / Passivo Circulante	88	16	104
Capital de Giro / Total do Ativo	74	0	74
Lucros Acumulados / Total do Ativo	68	4	72
EBIT / Total do Ativo	54	0	54
Vendas / Total do Ativo	50	4	54
(Ativo Circulante - Estoques) / Passivo Circulante	46	6	52
Dívida Total / Total Ativo	41	0	41
Ativos Circulantes / Total Ativo	38	2	40
Lucro Líquido / Patrimônio Líquido	33	6	39
Caixa / Total do Ativo	25	6	31
Total do Passivo / Total do Ativo	27	0	27
Fluxo de Caixa Operacional / Total do Ativo	21	6	27
Valor Mercado Ações / Valor Contábil Dívida Total	22	0	22
Passivo Circulante / Total do Ativo	17	4	21
Fluxo de Caixa Operacional / Total do Passivo	19	0	19
Lucro Líquido / Vendas	12	8	20
Dívida Total / Patrimônio Líquido	10	12	22
Fluxo de Caixa Operacional / Dívida Total	16	0	16
EBIT / Juros	14	4	18
Total do Passivo / Patrimônio Líquido	10	10	20
(Ativo Circulante - Estoques) / Total do Ativo	15	0	15

continua

conclusão

Indicadores financeiros utilizados na previsão de falência	Frequência estudos internacionais	Frequência estudos nacionais	Total
Estoques / Vendas	14	2	16
Vendas Líquidas / Total do Ativo	7	12	19
Ativo Circulante / Vendas	14	0	14
Lucro Operacional / Total do Ativo	14	0	14
Fluxo de Caixa Operacional / Vendas	12	2	14
Patrimônio Líquido / Total do Ativo	10	6	16
Dívida de Longo Prazo / Total do Ativo	10	0	10
Capital de Giro / Total do Ativo	7	4	11
Caixa / Passivo Circulante	9	0	9
Fluxo de Caixa Operacional / Passivo Circulante	9	0	9
Capital de Giro / Vendas	9	0	9
Patrimônio Líquido / Total do Passivo	7	2	9
(Ativo Circulante - Estoques - Passivo Circulante) / Despesas Operacionais	7	0	7
Logaritmo do Total do Ativo	7	0	7
Capital de Giro / Patrimônio Líquido	6	2	8
Fluxo de Caixa (usando Lucro Líquido) / Total da Dívida	6	0	6
Fluxo de Caixa Operacional	6	0	6
Despesas Operacionais / Lucro Operacional	6	0	6
(Ativo Circulante - Estoques) / Vendas	6	0	6
Vendas / Estoques	6	0	6
Ativo Permanente / Patrimônio Líquido	0	6	6
Empréstimos / Ativo Circulante	0	4	4

Fonte: adaptado de Pereira e Martins (2016)

A Tabela 5 apresenta a frequência dos principais indicadores utilizados nos estudos nacionais e estrangeiros, claramente influenciados pelos modelos estatísticos clássicos – como Altman (1968) –, por meio da concentração de indicadores financeiros, em sua maioria extraídos dos BP e DRE das organizações, situação que é agravada se observarmos apenas as publicações nacionais. Jones et al. (2017) apresenta conclusões semelhantes avaliando a relevância das variáveis para determinados modelos de previsão mais modernos (*random forests*), evidenciando a relativa importância atribuída aos indicadores vinculados aos fluxos de caixa das organizações, em detrimento dos demais indicadores financeiros.

Aliados à uma abordagem teórica ou estatística, esses indicadores financeiros, extraídos, em sua maioria, dos BP e DRE das organizações, fazem parte do *mainstream* das pesquisas em previsão de falência (Yu et al., 2014), mesmo diante de inúmeras evidências de

que a adoção de indicadores e métodos alternativos tem o potencial de apresentar resultados mais eficazes e promissores (Jones et al., 2017; Jones, 2017; Jones et al., 2015).

Com efeito, Tinoco e Wilson (2013) avaliam modelos de previsão com variáveis contábeis, macroeconômicas e de mercado, concluindo que a eficácia dos resultados obtidos é mais acurada quando essas variáveis são tratadas de forma não excludente. Ainda que o fluxo de caixa operacional, de forma isolada, não se destaque como variável de previsão de insolvência (Casey & Bartczack, 1985), para Tinoco e Wilson (2013), a conjugação de informações contábeis, de mercado e dados macroeconômicos pode explicar, ao menos em parte, a (in)solvência das organizações dentro de seus ciclos de negócios (Drobetz et al., 2017; Robinson & Sensoy, 2016).

Tabela 6 - Variáveis contábeis selecionadas

Variável	Sigla	Fórmula	Referência
Fluxo sobre LL	FCO sobre LL	caixa líquido gerado atividades operacionais na DFC / LL na DRE	Aziz (1988); Dickinson (2011)
Crescimento anual FCO	ΔFCO	crescimento % do FCO na DFC em relação ao ano anterior	Jones et al (2017)
Crescimento anual LL	ΔLL	crescimento % do LL na DRE em relação ao ano anterior	Jones et al (2017)
Crescimento anual RT	ΔRT	crescimento % da RT na DRE em relação ao ano anterior	Jones et al (2017)
Giro do Ativo	Giro Ativo	Receita Bruta Vendas na DRE / AT no BP	Altman (1968); Dickinson (2011); Azayite & Achchab (2016); Wang et al (2017)
Margem Líquida	Margem Líquida	Receita Bruta Vendas na DRE / LL na DRE	Elizabetsky (1976); Dickinson (2011); Wang et al (2017)

Fonte: elaborado pelo autor

A pesquisa bibliográfica permitiu identificar os principais fatores que impactam a solvência das organizações; a seleção das variáveis priorizou a utilização dos indicadores de fluxo de caixa (Tabela 6), em detrimento daquelas mais comumente utilizadas nos modelos clássicos, exclusivamente de BP e DRE.

Embora o IAS 7 – *Statement of Cash Flow*s e o CPC 03 assegurem certa flexibilidade das escolhas contábeis envolvendo elementos da DFC, principalmente os juros e dividendos pagos – que podem ser classificados tanto nas atividades operacionais como nas atividades de financiamento – e os juros e dividendos recebidos – que se classificam ora como atividades operacionais, ora como atividades de investimento –, o item 34A do CPC 03:

> encoraja fortemente as entidades a classificarem os juros, recebidos ou pagos, e os dividendos e juros sobre o capital próprio recebidos como fluxos de caixa das atividades operacionais, e os dividendos e juros sobre o capital próprio pagos como fluxos de caixa das atividades de financiamento (CPC, 2010).

Já para o *United States Generally Accepted Accounting Principles* (USGAAP) a classificação como atividade operacional é obrigatória para os juros pagos e recebidos e para os dividendos recebidos, existindo evidências de que essa classificação é majoritariamente adotada também nos demais países que adeptos às IFRS, inclusive o Brasil (Scherer et al., 2012; Gordon et al., 2017; Silva et al., 2014; Maciel, 2015) – ademais, no país, eventual alternativa diferente deve ser seguida de nota explicativa, de acordo com o CPC 03, razão pela qual não se fará qualquer distinção no que toca aos componentes do FCO das empresas analisadas

Por fim, ainda que existam evidências contrárias à eficácia do fluxo de caixa operacional (FCO) como indicador de insolvência, quando isoladamente analisado (Casey & Bartczack, 1985), para Dickinson (2011) trata-se de uma medida importante para avaliar os ciclos de negócios das organizações (Drobetz et al., 2017; Robinson & Sensoy, 2016), mormente quando aliado a outras informações de grandeza econômica (Tinoco & Wilson, 2013).

Tabela 7 - Variáveis macroeconômicas e de mercado

Variável	Sigla	Fórmula	Referência
Idade	LNIdade	Logaritmo Natural (Ln) Idade da entidade	Jones et al (2017); Dickinson (2011)
Setor	Setor	*Dummy*: Indústria (1) ou Comércio e Serviços (0)	Jones et al (2017)
Tamanho	LNTam	Ln AT	Dickinson (2011)
Taxa Selic	Selic	Taxa SELIC anual acumulada, divulgada pelo Bacen, equivalente nacional a *Treasury Rate*	Tinoco e Wilson (2013)
IPCA	IPCA	IPCA anual acumulado, divulgado pelo IBGE, equivalente ao *Retail Price Index*	Tinoco e Wilson (2013)

Fonte: elaborado pelo autor

Buscando aprimorar a eficácia do modelo, outras variáveis de natureza macro e microeconômica (ou de mercado) foram selecionadas na Tabela 7, a partir dos indicadores propostos por Tinoco e Wilson (2013) e Jones et al. (2017).

O trabalho de Dickinson (2011) envolvendo os ciclos de vida das organizações permite duas inflexões importantes, no que toca aos Fluxos de Caixa de Investimento (FCI) e de Financiamento (FCF) e a sua relação com a solvência das empresas:

Tabela 8 - Comportamento dos fluxos de caixa no ciclo de vida das organizações

Natureza	Introdução	Crescimento	Maturidade	Oscilação	Declínio
FCO	(-)	(+)	(+)	(+/-)	(-)
FCI	(-)	(-)	(-)	(+/-)	(+)
FCF	(+)	(+)	(-)	(+/-)	(+/-)

Fonte: adaptado de Dickinson (2011)

Levantamento do Serviço Brasileiro de Apoio às Micro e Pequenas Empresas (Sebrae) aponta a "falta de capital" como o principal fator alegado para o fechamento de empresas no país (Sebrae, 2014); a tentativa de obtenção de capital também reflete-se no movimento dos fluxos de caixa das organizações, seja através da expansão das atividades operacionais em fases de crescimento[1] ou também por meio da obtenção de financiamentos ou alienação de bens da organização, que produzem, nos fluxos de caixa, os efeitos esperados por Dickinson (2011).

Com se observa da Tabela 8, nas fases de oscilação e declínio, o comportamento esperado do FCI e do FCF é positivo, o que pode ser explicado pela necessidade da empresa em buscar recursos para fazer frente às suas obrigações nos períodos de arrefecimento do FCO, seja por meio da alienação de ativos da companhia ou obtenção de empréstimos e financiamentos, eventos que resultariam em FCI e FCF positivo.

Tabela 9 - Variáveis de fluxo de caixa propostas

Variável	Sigla	Fórmula
Fluxo de Caixa Líquido de Investimento	FCI	*Dummy*: se positivo (1) ou negativo (0)
Fluxo de Caixa Líquido de Financiamento	FCF	*Dummy*: se positivo (1) ou negativo (0)

Fonte: elaborado pelo autor

[1] Capturado pela variável FCO proposta na Tabela 6.

Igualmente, os fluxos de caixa são variáveis que se alteram ao longo do tempo e se adaptam melhor a modelos dinâmicos, como é o caso das RNA (Thomas, Ho & Scherer, 2001); além disso, como a proposta de Dickinson (2011) é identificar o comportamento esperado dos fluxos de caixa ao longo do ciclo de vida de uma organização, foi necessário adotar uma codificação para representação desses dados, sob a forma de variáveis *dummy*, o que representa uma importante vantagem computacional para o modelo, pois a entrada de uma RNA não seria capaz de interpretar esse tipo de informação qualitativa.

A Tabela 9 contém as variáveis de fluxo de caixa adicionais propostas neste trabalho, com base no efeito esperado do FCI e do FCF nas diferentes etapas do ciclo de vida das organizações apresentadas por Dickinson (2011).

A conjugação das variáveis selecionadas a partir da literatura de referência na Tabela 6 e na Tabela 7, com os indicadores propostos nesse trabalho na Tabela 9, visa encampar, no modelo, as variáveis que contemplam a teoria construída. de que os fluxos de caixa das organizações podem se mostrar fatores determinantes na previsão da recuperação judicial.

A Tabela 10 abaixo sumariza as variáveis selecionados para o modelo desenvolvido, agrupadas de acordo com a sua natureza:

Tabela 10 - Variáveis selecionadas

Natureza	Variável	Sigla	Fórmula
Dependente (*output*)	Tempo	T	tempo até o pedido de RJ
	RJ	RJ	*Dummy*: RJ (1) ou solvente (0)
Contábeis	Fluxo sobre LL	FCO sobre LL	caixa líquido gerado atividades operacionais na DFC / LL na DRE
	Crescimento anual FCO	ΔFCO	crescimento % do FCO na DFC em relação ao ano anterior
	Crescimento anual LL	ΔLL	crescimento % do LL na DRE em relação ao ano anterior
	Crescimento anual RT	ΔRT	crescimento % da RT na DRE em relação ao ano anterior
	Giro do Ativo	Giro Ativo	Receita Bruta Vendas na DRE / AT no BP
	Margem Líquida	Margem Líquida	Receita Bruta Vendas na DRE / LL na DRE
Macroeconômicas e de mercado	Idade	LNIdade	LN Idade
	Setor	Setor	*Dummy*: Indústria (1) ou Comércio e Serviços (0)
	Tamanho	LNTam	LN AT

continua

conclusão

Natureza	Variável	Sigla	Fórmula
	Taxa Selic	Selic	Taxa SELIC anual acumulada, divulgada pelo Bacen, equivalente nacional a *Treasury Rate*
	IPCA	IPCA	IPCA anual acumulado, divulgado pelo IBGE, equivalente nacional ao *Retail Price Index*
Fluxo de Caixa	Fluxo de Caixa Líquido de Investimento	FCI	*Dummy*: se positivo (1) ou negativo (0)
	Fluxo de Caixa Líquido de Financiamento	FCF	*Dummy*: se positivo (1) ou negativo (0)

Fonte: elaborado pelo autor

3.2. Determinação da amostra e coleta de dados

Pereira e Martins (2016), Jones et al. (2017) e Rosa e Gartner (2018) também se debruçam sobre a controvérsia em torno do tamanho da amostra, uma vez que as evidências obtidas na literatura de referência indicam uma variação sensível em razão do modelo e das variáveis adotadas.

Outras restrições também são encontradas no caso concreto, dentre as quais pode-se destacar, por relevância: (i) o número reduzido de companhias abertas na Bolsa de Valores – Brasil, Bolsa, Balcão (B3) atualmente em recuperação judicial; (ii) a instituição tardia da DFC no Brasil, apenas a partir da edição da Lei nº. 11.638, de 28 de dezembro de 2007; (iii) as limitações legais em torno da obrigatoriedade de publicação das demonstrações financeiras (artigo 176, § 6º da LSA e artigo 3º da Lei nº. 11.638/07) e da exigência de auditoria independente (artigo 177, §3º da LSA); e, por conseguinte, (iv) a necessidade de coleta de dados primários, junto aos Diários Oficiais e Juntas Comerciais de 25 (vinte e cinco) Estados brasileiros.

A questão em torno do método de divulgação da DFC também foi avaliada; isso porque, de acordo com o item 18 do CPC 03 as entidades devem apresentar os FCO usando alternativamente:

(i) o método direto, segundo o qual as principais classes de recebimentos brutos e pagamentos brutos são divulgadas; ou,

(ii) o método indireto, segundo o qual o lucro líquido ou o prejuízo é ajustado pelos efeitos de transações que não envolvem caixa, pelos efeitos de quaisquer diferimentos ou apropriações por competência sobre recebimentos de caixa ou pagamentos em caixa operacionais passados ou futuros, e pelos efeitos de itens de receita ou despesa.

Antes da obrigatoriedade da DFC no país coletavam-se indícios da preferência pelo método direto (Salotti & Yamamoto, 2007), em função do seu conteúdo mais abrangente. Todavia, apesar de reforçarem os argumentos acerca da qualidade informacional do método direto, Andrade e Silva (2017), constataram a preferência das companhias pelo método indireto, em função, entre outros, dos custos de preparação da informação contábil, sua conexão com as demais demonstrações financeiras e a melhor compreensão dos usuários.

Ainda que o número de pesquisas averiguando, especificamente, a escolha do método de divulgação do FCO seja reduzido (Andrade & Silva, 2017), a preferência pelo método indireto é evidenciada também por dados brasileiros (Scherer et al., 2012) e estrangeiros (Brahmasrene et al., 2004), sempre reconhecendo as qualidades do seu concorrente, o método direto.

Levando-se em conta a preferência das organizações pela adoção do método indireto e, também o fato de que essa escolha – entre o método direto e o indireto – influencia apenas a forma de divulgação do FCO, mas não o seu resultado, não há razão que justifique essa distinção na formação a amostra.

Assim, na determinação da amostra e coleta de dados foram adotadas as seguintes etapas:

(i) primeiramente, realizou-se o levantamento das DFC de 50 (cinquenta) companhias brasileiras – abertas e fechadas, constituídas sob a forma de sociedade por ações (S/A) ou sociedades limitadas (LTDA) – em recuperação judicial, por meio de consulta de dados primários junto ao Poder Judiciário, Juntas Comerciais e B3, no período compreendido entre 31 de dezembro de 2008 (quando a Lei nº. 11.638/07 tornou a DFC obrigatória) e 31 de dezembro do ano-calendário imediatamente anterior à distribuição do pedido de RJ;

(ii) a estrutura da amostra indicada no item (i) foi reproduzida para formar um grupo de controle, com o mesmo número de componentes, só que, neste caso, no período compreendido entre 31 de dezembro de 2008 e 31 de dezembro de 2017;

(iii) os dados das 100 (cem) empresas coletadas foram analisados e tratados, chegando-se a uma amostra final composta de 94 (noventa e quatro) empresas, sendo metade delas (47) em recuperação judicial e a outra metade de companhias (47) solventes, para seleção das variáveis indicadas na Tabela 10, que resultou em 669 (seiscentas e sessenta e nove) observações.

O número de empresas integrantes da amostra encontra-se compatível com os levantamentos semelhantes apresentados por Pereira e Martins (2016), Jones et al. (2017) e Rosa e Gartner (2018), em se tratando de companhias fechadas e dados primários. Além disso, a estrutura da amostra e do grupo de controle é bastante semelhante em termos geográficos, contendo observações de companhias de todas as regiões brasileiras. A representação setorial também encontra paralelo entre a amostra e o grupo de controle:

Tabela 11 – Distribuição setorial da amostra e do grupo de controle

Empresas/Setor	Indústria	Comércio e Serviços
Recuperação Judicial	26	21
Solventes	21	26

Fonte: elaborado pelo autor

3.2.1. Estatística descritiva

Verificada como se deu a determinação da amostra, importa também investigar como as observações/variáveis se comportam a partir do campo da estatística descritiva.

Tabela 12 - Estatística descritiva

Geral	Selic	IPCA	Tamanho	FCO sobre LL	Δ FCO	Δ LL	Δ RT	Giro Ativo	Margem Líquida
Média	0,101	0,061	5,702	16,836	-2,170	-3,820	1,512	0,637	-0,651
Mediana	0,095	0,059	5,888	0,632	-0,123	-0,417	0,101	0,491	0,020
D. Pad.	0,016	0,018	1,224	362,869	206,587	76,234	24,452	0,639	15,894

continua

conclusão

Geral	Selic	IPCA	Tamanho	FCO sobre LL	Δ FCO	Δ LL	Δ RT	Giro Ativo	Margem Líquida
Máximo	0,132	0,107	8,012	9.356,10	2.901,00	1.004,70	604,17	5,838	126,545

RJ	Selic	IPCA	Tamanho	FCO sobre LL	Δ FCO	Δ LL	Δ RT	Giro Ativo	Margem Líquida
Média	0,099	0,061	5,660	38,136	12,521	-6,944	0,993	0,653	-0,310
Mediana	0,095	0,059	5,825	0,025	-0,426	-1,285	-0,007	-0,48	-0,024
D. Pad.	0,015	0,016	1,073	583,816	185,634	118,183	11,409	0,701	6,391
Mínimo	0,079	0,030	1,662	-64,922	-437,352	-1.538,00	-2,693	-0,28	-49,993
Máximo	0,132	0,107	8,012	9.356,100	2.901,00	1.004,70	179,732	5,838	73,139

Não RJ	Selic	IPCA	Tamanho	FCO sobre LL	Δ FCO	Δ LL	Δ RT	Giro Ativo	Margem Líquida
Média	0,102	0,061	5,728	3,550	-11,334	-1,872	1,836	0,626	-0,864
Mediana	0,095	0,059	6,037	0,935	-0,037	-0,081	0,130	0,493	0,040
D. Pad.	0,017	0,019	1,310	35,352	218,362	27,126	29,840	0,598	19,623
Mínimo	0,079	0,030	0,699	- 43,085	-4.123,00	-497,745	-1,000	-	-300,611
Máximo	0,132	0,107	7,659	674,516	975,626	55,838	604,170	3,226	126,545

Fonte: elaborado pelo autor

Na Tabela 12 são reportadas as estatísticas descritivas das variáveis que serão utilizadas no modelo, em que as observações foram extraídas da amostra, resumindo as médias aleatórias e os desvios padrão para os dados em painel – uma vez formatados esses os dados, as variáveis selecionadas na Tabela 10 serão implementadas por intermédio das RNA e LOGIT.

3.3. Modelos utilizados

Como detalhado, diversos autores (Yu et al., 2014; Jones et al., 2017; Jones, 2017; Jones et al., 2015) apontam evidências de que modelos não tradicionais também contribuem para melhorar a eficácia das previsões, embora subutilizados pelos pesquisadores, em sua maioria. Pereira e Martins (2016) e Rosa e Gartner (2018) corroboram tal afirmação ao evidenciar a pouca concentração da aplicação de métodos de inteligência artificial para dados

brasileiros e mundiais, fenômeno que também aparece nos levantamentos realizados por Aziz e Dar (2006).

Além da escolha dos modelos aplicados à amostra, outra questão de grande relevância é a definição do evento de interesse que se pretende prever e/ou estimar. Isso porque, embora a grande maioria das pesquisas na área estabeleça o momento em que a falência é decretada ou o momento em que a empresa entra em insolvência técnica (Wruck, 1990), é com o pedido de recuperação judicial que a organização sinaliza mais fortemente aos *stakeholders* a sua situação econômico-financeira e a necessidade de buscar uma reorganização para manutenção dos contratos e obrigações.

Isso porque, como se viu, de acordo com os artigos 50 e 58 da LRF, dentre os meios para reorganização da empresa, pode-se incluir a "*concessão de prazos e condições especiais para pagamento das obrigações vencidas ou vincendas*", caracterizando uma renegociação forçada dos créditos da entidade que pode até mesmo ser implementada à revelia de parte dos credores, por determinação judicial (*cram down*).

Ademais, embora de acordo com o artigo 51 da LRF, para buscar a recuperação judicial, deva-se compartilhar "*a exposição das causas concretas da situação patrimonial do devedor e das razões da crise econômico-financeira*", isso necessariamente não significa que a empresa se encontre já naquele momento em situação de insolvência, razão pela qual, cada dia mais, tem-se caracterizado a recuperação judicial como uma verdadeira alternativa à insolvência.

Afora o fato de, na grande maioria das vezes, a recuperação judicial anteceder a decretação da falência (Figura 2) – sendo considerada uma situação pré-falimentar –outro aspecto que a destaca positivamente como evento de interesse é o chamado "*stay period*", assim conhecido o intervalo máximo de "*180 (cento e oitenta), contado do deferimento do processamento da recuperaçã*o" (art. 6º, §4º da LRF) em que se suspendem todos os processos de cobrança contra a organização, impedindo os credores de buscarem o recebimento dos seus créditos, que, ao final, poderão vir a ser objeto de renegociação forçada, com significativos deságios e prorrogações, a despeito dos seus próprios interesses.

Não se pode olvidar também o fato de que a mera apresentação do pedido de recuperação judicial pelo devedor – independentemente do seu deferimento ou não – tem um efeito negativo tanto na precificação desses créditos (*market value*), que se denota pelo avanço do mercado de ativos defaultados (ou créditos *distressed*) brasileiros, quanto na classificação de *rating* dos investidores, inclusive para contratos que, aquele tempo, não se encontravam inadimplidos.

A mesma premissa pode ser observada em relação ao tratamento tributário atribuído aos créditos das companhias em recuperação judicial, que, diferentemente das demais perdas estimadas em crédito de liquidação duvidosa (PECLD), podem ser integralmente deduzidos, independentemente do valor, nos termos do artigo 9º, §1º, inciso IV, da Lei nº. 9.430, de 27 de dezembro de 1996.

Além disso, Gilson (1991) alerta para a grande influência do juiz nos negócios da companhia na recuperação judicial, que pode atrasar a tomada de decisão e levar a deliberações equivocadas em torno da utilização dos ativos da empresa, afetando a sua performance.

Portanto, enquanto no evento de falência o credor deverá concorrer com os demais interessados para recebimento do seu crédito, limitado ao produto da liquidação dos ativos da organização, e, na insolvência, ocorre o não cumprimento pontual das obrigações contratuais da entidade, a recuperação judicial – além de, regra geral, antecipar-se à falência e poder, ou não, anteceder a insolvência – é o momento inicial em que se altera a percepção de valor do crédito, uma vez que as obrigações contratuais da entidade podem ser severamente modificadas, em detrimento dos interesses dos credores e *stakeholders*.

Por essas razões é que o pedido de recuperação judicial – e não a decretação da falência ou a constatação da insolvência – é o momento mais apropriado para caracterizar o evento de interesse que se pretende prever e/ou estimar, ainda que a grande maioria das pesquisas sobre o tema não utilize a recuperação judicial como marco determinante dos modelos de previsão ou, pior ainda, não faça distinção entre esta e a falência[2].

3.3.1. Redes neurais artificiais

As RNA são ferramentas de inteligência artificial que, por intermédio de um conjunto de dados, são capazes de se auto adaptar e auto ajustar (aprendizagem) para realizar uma atividade determinada ou um comportamento esperado como, por exemplo, estabelecer se a entidade buscará ou não a recuperação judicial como alternativa a insolvência.

[2] Outra distinção importante é entre o conceito de *failure* – quando a taxa de retorno sobre o capital investido é sistematicamente inferior às taxas comuns de mercado – e o de *bankruptcy* (falência) – quando a companhia não tem mais capacidade de fazer frente às suas obrigações. Para Altman (1983), o estado de *failure* não se confunde com a falência, pois não necessariamente resulta no descumprimento de obrigações pela empresa, diferentemente da hipótese de insolvência.

Figura 3 - Representação de uma RNA

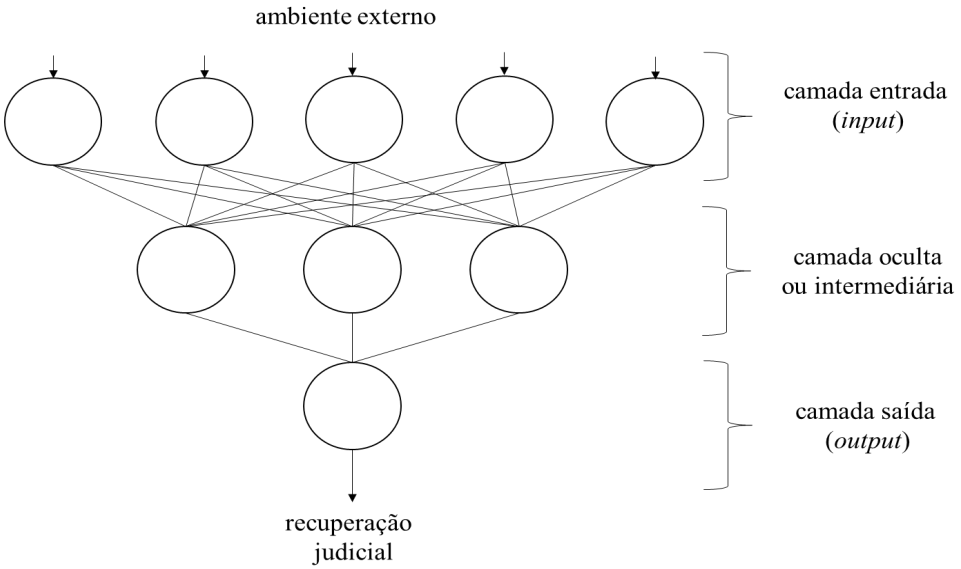

Fonte: elaborado pelo autor

O seu modelo de processamento de informações é baseado nos neurônios que, biologicamente, equiparam-se a unidades de processamento, realizando uma série de funções matemáticas a partir das informações coletadas (*input*); as sinapses atribuem valor aos resultados dessas funções para que o raciocínio do processo seja a obtenção do evento/comportamento esperado (*output*). De forma computacional, as informações interligam-se por uma rede na qual cada unidade recebe e combina uma série de entradas numa única saída, que dá entrada a uma nova unidade até a saída final da rede, ou a resposta do problema (Bialoskorski, Nagano & Moraes, 2006).

A escolha das RNA se justifica vez que a técnica é menos sensível a problemas quanto à distribuição e ao tamanho da amostra, que não têm reflexo tão significante nos resultados quanto nos modelos estatísticos tradicionais (Trippi & Lee, 1996). Embora questões como a multicolinearidade das variáveis também representem problemas menores, é possível eliminar as variáveis altamente correlacionadas por meio de testes estatísticos, tornando o modelo mais eficiente sem o uso de todas as variáveis contábeis (Trippi & Lee, 1996).

Para implementação das RNA serão observadas as seguintes etapas (Bialoskorski, Nagano & Moraes, 2006; Zhang et al., 1998; Khashei & Bijari, 2010):

(i) definição da rede (preparação de modelo teórico dos resultados esperados para a amostra e o grupo de controle);

(ii) treinamento (indicação dos dados de entradas e os resultados de saída esperados, juntamente com os pesos das correlações indicadas no modelo teórico para validação das RNA);

(iii) utilização da RNA (momento no qual as RNA passam a fornecer dados confiáveis, posto que validadas as suas premissas e correlações); e,

(iv) manutenção (a volatilidade do ambiente exige a revisão dos pesos atribuídos à certas correlações e/ou variáveis mais significativas, tornando-se necessária, inclusive, uma nova etapa de treinamento).

As etapas (i) e (ii) são decisivas na preparação da rede: neste trabalho, utilizar-se-á uma RNA *feed forward* (Figura 3), em que os neurônios (ou neurons) são ordenados em fase ou camadas, com cada camada se conectando a próxima fase da rede, sem conexões de retorno, isto é, sem caminho de volta. Isso significa que todas conexões da RNA se movem numa única direção, da camada de entrada (*input*) até a fase de saída (*output*), sem referências circulares ou *loops* no raciocínio da rede (Azayte & Achchab, 2016).

O algoritmo de *back propagation* é um dos principais métodos aplicados para o treinamento de RNA *feed forward* (Azayte & Achchab, 2016; Wang et al, 2015). Calculando-se o erro esperado, o algoritmo corrige os pesos atribuídos em cada uma das camadas, partindo da camada de saída até a camada de entrada, de forma a assegurar que o *output* seja o resultado dos *inputs* da RNA.

Cada RNA tem uma arquitetura própria. O modelo proposto será seccionado em 03 (três) camadas (Figura 3): uma camada de entrada, uma fase intermediária (*hydden*) [3] e uma camada de saída. O número de neurônios – das camadas de entrada e intermediária – estará diretamente relacionado a tarefa atribuída à rede; cada neurônio da camada de entrada representará uma das variáveis selecionadas (*input*) e a camada de saída deverá retornar um padrão ao ambiente externo (*output*), caracterizado por uma variável binária (*dummy*) que separe as empresas em recuperação judicial das companhias saudáveis.

[3] Apesar de não interagirem diretamente com o ambiente externo, as fases intermediárias exercem significativa influência no funcionamento da RNA, todavia, são raros os problemas que exigem mais de uma camada intermediária.

3.3.2. LOGIT e modelos de regressão

Os modelos de regressão são uma das ferramentas estatísticas mais importantes na análise de dados, principalmente em se tratando de avaliar as relações entre as variáveis existentes num determinado conjunto/amostra.

Para Fávero (2015) o objetivo maiores desses modelos é explorar a relação entre uma ou mais variáveis explicativas – ou independentes – e uma variável de resposta – ou dependente. Um dos casos específicos de modelos lineares generalizados são os modelos nos quais a variável resposta apresenta apenas duas categorias (0;1), sendo o modelo de regressão logística o mais popular dentre eles.

A regressão logística – ou LOGIT –, semelhante ao modelo de regressão linear, caracteriza-se pelo fato de a variável dependente ter natureza categórica ou binária, isto é, a resposta da LOGIT assume dois valores entre 0 ou 1, também denominados como "fracasso" e "sucesso" (Sweeney et al, 2013).

A técnica tem como objetivo modelar, a partir de um dado conjunto de observações, a relação "logística" entre a variável dependente dicotómica (0;1) e uma série de outras variáveis explicativas, que podem assumir valores numéricos, contínuos, discretos ou mesmo categóricos (Hosme & Lemeshow, 2000).

Especificamente em se tratando de trabalhos envolvendo a previsão de insolvência, a utilização de modelos de regressão em geral está ligada à própria origem desse ramo de pesquisa, como apontam Pereira e Martins (2016):

Tabela 13 - Técnicas de regressão aplicadas

Ano	Autor(es)	Qt. Indicadores	Amostra	Modelo	Eficiência do Modelo
1966	Beaver	30	Geral	análise discriminante univariada	Melhor indicador com 92%
1968	Altman	5	Indústrias de Capital Aberto	análise discriminante multivariada	79%
1978	Kanitz	5	Pequenas e Médias Empresas	análise discriminante multivariada	78% (falidas)
1978	Matias	6	Empresas Capital Aberto	análise discriminante multivariada	74% (falidas)
1980	Ohlson	9	Geral	LOGIT	96%

continua

Conclusão

Ano	Autor(es)	Qt. Indicadores	Amostra	Modelo	Eficiência do Modelo
1985	Casey e Bartczack	9	Geral	LOGIT	63% (insolvente) e 98% (solvente)
1988	Aziz, Emanuel e Lawson	6	Geral	LOGIT e análise discriminante	88,8%
1990	Gilbert et al	6	Geral	LOGIT	62,5% (insolventes) e 97,9% (solventes)
1991	Luoma e Laitinien	7	Empresas finlandesas	LOGIT e análise discriminante	64,7% (solventes) e 76,5% (insolventes)
2013	Tinoco e Wilson	10	Geral	LOGIT	89,2%
2017	Jardin	50	Empresas Financeiras	LOGIT, análise discriminante, RNA e outros	84,5%

Fonte: adaptado pelo autor a partir de Pereira e Martins (2016)

A Tabela 13 demonstra que a aplicação de técnicas de regressão – e, em especial, a LOGIT – são uma constante envolvendo pesquisas na área de previsão de insolvência, desde os trabalhos inicias de Altman (1968), passando pelos principais modelos brasileiros na década de 1970 (Matias. 1978; Kanitz, 1978) até trabalhos mais recentes, como Tinoco e Wilson (2013).

A utilização sistemática da LOGIT, nesses casos, se justifica na medida em permite estimar a probabilidade associada à ocorrência de determinado evento (insolvência) em face de um conjunto de variáveis explanatórias.

Assim, para fins deste trabalho, o modelo proposto a partir da utilização das RNA para previsão da ocorrência da RJ e, também, do tempo (T) estimado até esse evento, será confrontado também com os resultados obtidos a partir da LOGIT, como Jardin (2017).

4. RESULTADOS E ANÁLISES

4.1. Regressão linear e LOGIT

Primeiramente os dados foram submetidos a testes de normalidade, heterocedasticidade e multicolinearidade, obtendo-se os resultados:

Tabela 14 – Testes de normalidade e multicolinearidade

Variável	Prob>z	1/VIF
FCOsobreLL	0,000000	0,993511
FCO	0,000000	0,974239
LL	0,000000	0,970828
RT	0,000000	0,975330
GiroAtivo	0,000000	0,913826
MargemLíquida	0,000000	0,993799
LNIdade	0,000000	0,816169
Setor	0,000000	0,950646
LNTam	0,000000	0,955079
Selic	0,000000	0,694683
IPCA	0,000000	0,699053
FCI	0,000000	0,943000
FCF	0,000000	0,900053

Fonte: elaborado pelo autor a partir dos dados do Stata/SE 14.0

Tabela 15 – Teste de heterocedasticidade

RJ	Result.
chi2 (1)	1,91
p-valor	0,1672

Fonte: elaborado pelo autor a partir dos dados do Stata/SE 14.0

Os dados não apresentam problemas de multicolinearidade (VIF < 2,0 e 1/VIF >0,69) e heterocedasticidade (p-valor = 0,1672), porém verificou-se a não normalidade das observações (p-valor = 0,0000 em todas as variáveis), prejudicando a generalização de resultados.

Os dados foram então submetidos à regressão linear e à logística (LOGIT) – técnica tradicionalmente utilizada em pesquisas na área (Ohlson, 1980), principalmente envolvendo dados brasileiros (Elizabetsky, 1976; Kanitz, 1978; Matias, 1978; Altman, 1979) –, através do software Stata/SE 14.0, com a RJ como variável independente e as demais variáveis da Tabela 16 como variáveis independentes. Os resultados extraídos para regressão linear foram:

Tabela 16 – Regressão linear – f(RJ)

RJ	Coef.	Erro Padrão	t	p-valor
FCOsobreLL	0,0000587	0,0000513	1,14	0,253
FCO	0,0001598	0,0000910	1,76	0,079
LL	-0,0000685	0,0002469	-0,28	0,982
RT	-0,0007089	0,0007680	0,92	0,356
GiroAtivo	0,0297412	0,0303531	0,98	0,328
MargemLíquida	0,0005933	0,0011705	0,51	0,612
LNIdade	-0,0185020	0,0187499	-0,99	0,324
Setor	0,6712360	0,0381018	1,76	0,079
LNTam	-0,0060015	0,0067348	-0,89	0,373
Selic	-3,2901980	1,3514900	-2,43	0,015
IPCA	1,5879560	1,2236700	1,30	0,195
FCI	0,1512290	0,0554151	2,73	0,007
FCF	0,1289913	0,0394197	3,27	0,001
Cons	0,6329131	0,1559321	4,06	0,000
Número de Obs.	669			
p-valor (F)	0,0016			
R^2	0,0491			
RMSE	0,47935			

Fonte: elaborado pelo autor a partir dos dados do Stata/SE 14.0

Os resultados da LOGIT encontram-se detalhados na Tabela 17 e na Tabela 18:

Tabela 17 – LOGIT – f(RJ)

RJ	Coef.	Erro Padrão	z	p-valor
FCOsobreLL	0,000383	0,0005458	0,70	0,483
FCO	0,0012635	0,00096	1,32	0,188
LL	-0,0000975	0,0011227	-0,09	0,931
RT	-0,0033421	0,0041682	0,80	0,423
GiroAtivo	0,1329147	0,132924	1,00	0,317
MargemLíquida	0,0028163	0,005545	0,51	0,612
LNIdade	-0,0827975	0,081382	-1,02	0,309
Setor	0,2882122	0,1677607	1,72	0,086
LNTam	-0,0258921	0,0293078	-0,88	0,377
Selic	-14,99419	6,085482	-2,46	0,014
IPCA	7,283434	5,475743	1,33	0,183
FCI	0,6568503	0,238948	2,75	0,006
FCF	0,5672294	0,1728458	3,28	0,001
Cons	0,632933	0,6868076	0,92	0,357
Número de Obs.	669			
p-valor (F)	0,0010			
Pseudo R^2	0,0387			

Fonte: elaborado pelo autor a partir dos dados do Stata/SE 14.0

Tabela 18 – Classificação estatística – f(RJ)

	Verdadeiro		
Classificação	**D**	**~D**	**Total**
+	56	39	95
-	201	373	574
Total	257	412	669

Sensitividade	21,79%
Especificidade	90,53%
Valor preditivo positivo	58,95%
Valor preditivo negativo	64,98%
Falsa taxa + para ~D verd.	9,47%
Falsa taxa - para D verd.	78,21%
Falsa taxa + para classif. +	41,05%
Falsa taxa - para classif. -	35,02%
Classificação Correta	64,13%

Fonte: elaborado pelo autor a partir dos dados do Stata/SE 14.0

Os testes permitem concluir que o modelo não tem grande capacidade explicativa (R^2=0,0491) na regressão linear e o percentual de classificações corretas, na LOGIT, é de 64,13% (sessenta e quatro inteiros e treze centésimos por cento), sendo que a maioria dos erros classificatórios se encontra no grupo de "falso negativo", isto é, empresas classificadas como em RJ que não se encontram em RJ.

A regressão linear também foi aplicada em relação à variável dependente (T), que representa o tempo estimado até a organização requerer a RJ, mantendo-se como variáveis independentes aquelas contidas na Tabela 10. Os resultados obtidos estão reproduzidos abaixo:

Tabela 19 – Regressão linear – f(T)

T	**Coef.**	**Erro Padrão**	**T**	**p-valor|**
FCOsobreLL	0,0000499	0,0002881	0,17	0,862
FCO	0,0001027	0,0005111	0,20	0,841
LL	-0,0006753	0,0013875	-0,49	0,627
RT	-0,0005226	0,0043158	-0,12	0,904
GiroAtivo	0,7731372	0,1705638	4,53	0,000
MargemLíquida	-0,0021077	0,0065774	-0,32	0,749
LNIdade	-0,0238381	0,1053618	-0,23	0,821
Setor	0,1172172	0,2141063	0,55	0,584
LNTam	-0,0220535	0,0378449	-0,87	0,383
Selic	0,0801808	7,5944630	0,01	0,992

continua

conclusão

T	Coef.	Erro Padrão	T	p-valor|
IPCA	-3,0510510	6,8762010	-0,44	0,657
FCI	0,9162750	0,3113956	2,94	0,003
FCF	-0,1118000	0,2215121	-0,50	0,614
Cons	0,5787927	0,8762335	0,66	0,509
Observações	669			
p-valor (F)	0,0049			
R^2	0,0442			
RMSE	2,6936			

Fonte: elaborado pelo autor a partir dos dados do Stata/SE 14.0

Também em relação à variável independente (T) os testes permitem concluir que o modelo não tem grande capacidade explicativa (R^2=0,0442), mas já denota que as variáveis dependentes FCOsobreLL e FCO tem os menores erro padrão, o que tem relação com a hipótese discutida neste trabalho, de que os fluxos de caixa são determinantes para a RJ das organizações, como será melhor debatido adiante.

4.2. RNA para *output* RJ

Em seguida, os dados foram submetidos a análise por meio de RNA, para avaliar a capacidade de previsão da RJ a partir das variáveis selecionadas na Tabela 10.

Como detalhado no Capítulo 3, na escolha da configuração e respectivas RNA para compor esse modelo foram utilizadas redes *feed forward* (Figura 3), cujo treinamento se deu por meio de *back propagation* (Azayte & Achchab, 2016; Wang et al, 2015). A preparação das redes baseou-se na função de classificação *Multilayer Perceptron*, através do software Weka 3.8.3, e foram utilizados os seguintes parâmetros para treinamento:

(i) *learning rate* – variando entre 0,2 e 0,4, com alterações de 0,05; e,

(ii) *trainning test* – variando entre 500 e 50000, com alterações escalonadas de 500, 1000 e 5000.

O tempo de processamento e construção do modelo das RNA também variou entre 0.55 e 356,44 segundos e, ao final, foram testadas 96 (noventa e seis) RNA diferentes, para

identificação do modelo de previsão mais adequado. Os resultados obtidos no teste de *cross-validation* encontram-se reproduzidos abaixo:

Tabela 20 – *Cross-validation test* – RJ

Observações classificadas corretamente	457	68,31%
Observações classificadas incorretamente	112	31,69%
Erro médio absoluto	0,3458	
RMSE	0,4746	
Erro médio relativo	73,07%	
Raiz do erro relativo quadrado	97,58%	
Observações	669	

Fonte: elaborado pelo autor a partir dos dados do Weka 3.8.3

A Tabela 21 apresenta os percentuais de classificações corretas da RJ obtidos pelas RNA no teste *trainning set*:

Tabela 21 – Classificações corretas – RJ

RJ	Learning Rate	0,2	0,25	0,3	0,35	0,4
Trainning teste	500	81,6143%	83,7070%	81,3154%	77,4290%	77,5785%
	1000	81,6143%	85,5007%	82,5112%	79,3722%	78,3259%
	1500	82,2123%	85,5007%	82,8102%	80,4185%	78,1764%
	2000	82,3617%	85,5007%	82,8102%	80,4185%	78,6248%
	2500	82,2123%	85,5007%	82,9596%	80,7175%	78,6248%
	3000	82,3617%	85,7997%	82,8102%	81,3154%	79,0732%
	3500	82,6607%	85,9492%	83,4081%	81,1659%	79,0732%
	4000	82,6607%	86,2481%	82,9596%	81,1659%	79,2227%
	4500	82,9596%	86,2481%	83,2586%	81,1659%	79,0732%
	5000	82,8102%	86,2481%	83,4081%	81,1659%	79,5217%
	10000	82,9596%	86,3976%	83,5575%	81,4649%	79,9701%
	15000	83,2586%	87,2945%	83,8565%	81,4649%	80,1196%
	20000	83,1091%	87,5934%	84,4544%	81,7638%	80,1196%
	25000	83,2586%	87,7429%	84,3049%	82,0628%	80,1196%
	30000	83,1091%	87,8924%	81,3154%	82,2123%	79,9701%
	35000	82,9596%	88,1913%	82,6007%	82,2123%	79,8206%
	40000	82,9596%	88,1913%	84,3049%	82,2123%	79,8206%
	45000	82,9596%	88,1913%	83,1091%	82,2123%	79,6712%
	50000	83,2586%	88,0419%	83,2586%	82,2123%	79,8206%

Fonte: elaborado pelo autor a partir dos dados do Weka 3.8.3

Já na Tabela 22 é possível verificar o *Root Mean Square Error* (RMSE) dessas mesmas RNA:

Tabela 22 – RMSE – RJ

RJ	Learning Rate	0,2	0,25	0,3	0,35	0,4
Trainning teste	500	36,62%	35,23%	35,96%	40,07%	38,59%
	1000	36,30%	34,37%	34,60%	38,85%	38,01%
	1500	36,07%	34,15%	34,26%	37,77%	37,73%
	2000	35,81%	34,03%	34,16%	37,53%	37,57%
	2500	35,62%	33,92%	34,04%	37,34%	37,65%
	3000	35,62%	33,82%	34,09%	37,25%	37,56%
	3500	35,15%	33,74%	33,64%	37,24%	37,43%
	4000	35,00%	33,68%	33,62%	37,22%	37,31%
	4500	34,96%	33,62%	33,57%	37,16%	37,25%
	5000	34,73%	33,57%	33,51%	37,12%	37,18%
	10000	34,55%	33,19%	34,00%	36,85%	36,95%
	15000	34,01%	32,95%	33,24%	36,71%	36,77%
	20000	34,19%	32,73%	33,37%	36,61%	36,72%
	25000	34,22%	32,59%	33,48%	36,53%	36,73%
	30000	34,43%	32,51%	37,28%	36,43%	36,82%
	35000	34,42%	32,41%	35,78%	36,34%	36,86%
	40000	34,34%	32,34%	33,78%	36,28%	36,86%
	45000	34,25%	32,30%	34,90%	36,23%	36,74%
	50000	34,18%	32,25%	35,91%	36,19%	36,91%

Fonte: elaborado pelo autor a partir dos dados do Weka 3.8.3

Por fim, também foram avaliadas as correlações entre cada uma das variáveis selecionadas e o resultado da rede, através de um teste de correlação – *Correlation based Feature Selection* (CFS), aliada à correlação linear de Pearson's, uma vez que todas as variáveis são numéricas (ou foram transformadas em variáveis numéricas, no caso das variáveis *dummy*) – conforme proposto por Hall (1998):

Tabela 23 – Correlação dos atributos (RJ)

Classificação	Variável
14	FCF
11	Selic
13	FCI
8	LNIdade
3	ΔFCO
2	FCO sobre LL
9	Setor
4	ΔLL
10	LNTam
6	Giro Ativo
7	Margem Líquida
5	ΔRT
12	IPCA

Fonte: elaborado pelo autor a partir dos dados do Weka 3.8.3

4.3. RNA para *output* T

Também valendo-se do Weka 3.8.3 foram realizados os testes de *cross-validation, trainning set* e correlação dos atributos, a fim de avaliar a capacidade do modelo em estimar o lapso temporal (T) até a organização buscar a RJ. Os resultados encontram-se detalhados abaixo:

Tabela 24 – *Cross-validation* teste – T

Coeficiente de correlação	**0,1218**
Erro médio absoluto	1,4005
RMSE	4,37
Erro médio relativo	184,54%
Raiz do erro relativo quadrado	159,93%
Observações	669

Fonte: elaborado pelo autor a partir dos dados do Weka 3.8.3

Tabela 25 – Coeficiente de Correlação entre previsto e observado

T	**Learning Rate**	**0,2**	**0,25**	**0,3**	**0,35**	**0,4**
Trainning teste	500	63,27%	63,40%	63,41%	63,68%	63,94%
	1000	64,58%	64,78%	64,86%	65,04%	65,11%
	1500	65,30%	65,36%	65,53%	65,45%	65,76%
	2000	65,73%	65,69%	66,09%	65,96%	66,21%
	2500	66,19%	65,93%	66,70%	66,46%	66,46%
	3000	66,67%	66,13%	67,53%	66,88%	66,78%
	3500	67,30%	66,32%	68,54%	67,30%	67,19%
	4000	68,22%	66,53%	69,71%	67,71%	66,89%
	4500	69,53%	66,86%	70,71%	68,05%	65,96%
	5000	70,68%	67,51%	71,72%	68,32%	65,32%
	10000	73,62%	72,55%	74,35%	69,78%	68,06%
	15000	78,22%	74,58%	70,84%	71,09%	71,09%
	20000	65,12%	81,93%	87,13%	72,67%	69,09%
	25000	85,49%	64,91%	76,02%	78,77%	58,71%
	30000	86,63%	87,85%	65,01%	79,60%	58,46%
	35000	87,64%	67,12%	66,48%	84,23%	58,49%
	35500	87,65%	67,11%	66,48%	84,26%	58,51%
	36000	87,30%	67,10%	66,47%	84,30%	58,53%

Fonte: elaborado pelo autor a partir dos dados do Weka 3.8.3

Tabela 26 – RMSE – T

T	Learning Rate	0,2	0,25	0,3	0,35	0,4
Trainning teste	500	214,94%	214,48%	213,97%	212,63%	211,73%
	1000	211,27%	211,37%	210,35%	208,76%	209,76%
	1500	210,28%	209,89%	209,43%	208,20%	207,91%
	2000	209,77%	208,62%	208,74%	207,95%	207,27%
	2500	209,43%	207,74%	207,39%	208,16%	207,34%
	3000	208,83%	207,07%	205,46%	208,43%	206,73%
	3500	207,58%	206,43%	201,97%	207,98%	205,34%
	4000	205,05%	205,66%	197,86%	207,08%	206,70%
	4500	201,54%	204,50%	194,37%	206,18%	209,98%
	5000	197,67%	202,29%	193,46%	205,26%	212,09%
	10000	184,78%	190,93%	183,65%	196,83%	200,93%
	15000	170,68%	184,49%	228,27%	194,31%	224,64%
	20000	214,79%	158,50%	135,15%	194,74%	224,64%
	25000	145,26%	217,34%	179,56%	177,80%	224,69%
	30000	140,24%	133,29%	211,65%	172,75%	225,01%
	35000	134,30%	205,50%	208,00%	150,16%	224,76%
	35500	134,30%	205,53%	207,99%	150,06%	224,71%
	36000	136,34%	205,57%	207,99%	149,93%	224,66%

Fonte: elaborado pelo autor a partir dos dados do Weka 3.8.3

Tabela 27 – Correlação dos atributos (T)

Classificação	Variável
14	Giro Ativo
11	FCI
13	LNIdade
8	Setor
3	ΔFCO
2	FCO sobre LL
9	Margem Líquida
4	ΔRL
10	LNTam
6	ΔLL
7	IPCA
5	Selic
12	FCF

Fonte: elaborado pelo autor a partir dos dados do Weka 3.8.3

4.4. Análise e discussões

Analisando os resultados obtidos, é possível identificar as RNA que apresentaram a maior capacidade de classificação da RJ na Tabela 28:

Tabela 28 – Melhores classificações– RJ

RJ	Learning Rate	0,25	RMSE
Trainning test	35000	88,1913%	32,41%
	40000	88,1913%	32,34%
	45000	**88,1913%**	**32,30%**
	50000	88,0419%	32,25%

Fonte: elaborado pelo autor a partir dos dados do Weka 3.8.3

Ainda dentre as melhores classificações obtidas, é possível verificar que a RNA que conjuga a melhor capacidade classificatória foi capaz de classificar corretamente 88,1913% das empresas que integram a amostra, apresentando ainda o melhor RMSE (32,30%) dentre as melhores classificações obtidas pelas RNA.

O RMSE pode ser definido como a raiz do erro médio quadrático – ou desvio médio – da diferença entre o valor observado e o valor da previsão; trata-se de uma métrica normalmente utilizada para expressar a acurácia do modelo analisado, com a vantagem adicional de que o RMSE apresenta os valores do erro nas mesmas dimensões da variável analisada (Takacs, 1985; Zumel & Mount, 2014).

Ao compararmos essa RNA com os resultados apresentados pelo modelo mais tradicional da regressão linear (Tabela 16), é possível verificar que a capacidade de previsão da RNA excede em mais de 44% (quarenta e quatro por cento):

Tabela 29 – Comparativo RNA x regressão linear - RJ

Modelo	Classificação Correta	RMSE
Reg. Linear	64,130%	47,935%
RNA	88,191%	32,300%
Dif.	44,268%	32,617%

Fonte: elaborado pelo autor a partir dos dados do Weka 3.8.3 do Stata/SE 14.0

Nada obstante a superioridade do modelo proposto, necessário que a análise dos resultados vá além da mera confrontação dos erros e acertos da previsão, buscando outras

métricas que permitam avaliar, com maior profundidade, a acurácia do modelo proposto, dentre as quais podemos destacar a matriz de confusão (*confusion matrix*), utilizada para validar o processo de aprendizado supervisionado (Zumel & Mount, 2014) da RNA: como a amostra e o grupo de controle, contém, respectivamente, apenas empresas em RJ e organizações saudáveis, a matriz de confusão permite identificar os erros e acertos na saída final da rede em relação aos dois conjuntos (amostra e grupo de controle).

Tabela 30 – Matriz de confusão

	LOGIT			RNA		
Classificação	**D**	**~D**	**Total**	**D**	**~D**	**Total**
+	56	39	95	208	49	257
-	201	373	574	30	382	412
Total Geral	257	412	669	238	431	669

	LOGIT	RNA
Sensitividade	21,79%	87,40%
Especificidade	90,53%	88,63%
Valor preditivo positivo	58,95%	80,93%
Valor preditivo negativo	64,98%	92,72%
Falsa taxa + para ~D verd.	9,47%	11,37%
Falsa taxa - para D verd.	78,21%	12,60%
Falsa taxa + para classif. +	41,05%	19,07%
Falsa taxa - para classif. -	35,02%	7,28%
Classificação Correta	64,13%	88,19%

Fonte: elaborado pelo autor a partir dos dados do Weka 3.8.3 do Stata/SE 14.0

Além da acurácia, outro dado importante que pode ser obtido por intermédio da matriz de confusão é a relação entre especificidade e sensibilidade da saída da RNA, também conhecida como eficiência. Enquanto a especificidade permite avaliar a capacidade da RNA em prever corretamente as empresas que não estão em recuperação judicial (proporção do *true negative*), a sensibilidade retorna a proporção dos verdadeiros positivos (*true positive*), que nada mais é do que a capacidade do modelo em predizer as empresas em recuperação judicial.

A comparação entre a matriz de confusão da Tabela 30 também deixa evidente a eficiência superior das RNA (88,01%) em relação à LOGIT (56,16%), que consiste na média aritmética da sensibilidade e especificidade, de forma a balancear os verdadeiros positivos e negativos do modelo, medida essencial uma vez que a acurácia, de forma isolada, pode induzir a conclusões equivocadas sobre o modelo, pois não leva em consideração os acertos positivos e negativos.

Vê-se, portanto, que o modelo de RNA proposto, não apenas possui maior capacidade de previsão do que os modelos mais tradicionais, como também apresenta maior acurácia – a única exceção diz respeito à especificidade, que ainda é relativamente mais elevada no modelo LOGIT, cuja capacidade de previsão das empresas que não estão em RJ é relativamente superior, o que, contudo, não prejudica a eficiência do modelo RNA, significativamente mais elevada.

É possível também extrair, a partir dos resultados positivos, os modelos com melhor coeficiente de relação entre as variáveis selecionadas (Tabela 10) e o tempo estimado (T) até a organização requerer RJ:

Tabela 31 – Melhores classificações– T

RJ	Learning Rate	0,25	RMSE
Trainning test	**30000**	**87,85%**	**133,29%**
	35000	67,12%	205,50%
	35500	67,11%	205,53%
	36000	67,10%	205,57%

Fonte: elaborado pelo autor a partir dos dados do Weka 3.8.3

Dentre as melhores classificações obtidas, é possível verificar que a melhor correlação identificada é de 87,85% (oitenta e sete inteiros e oitenta e cinco por cento), com RMSE de 1,3329 – ou seja, em aproximadamente 88% (oitenta e oito por cento) das vezes o modelo é capaz de indicar o tempo (T) em que a organização irá buscar a RJ como alternativa à insolvência, superior aos modelos tradicionais.

Por fim, uma vez tendo-se demonstrado a superioridade da performance dos modelos propostos em relação às modelagens mais tradicionais, importa investigar também a confirmação da hipótese deste trabalho em relação às variáveis selecionadas (Tabela 10), as quais foram eleitas a partir das evidências demonstradas por autores como Tinoco e Wilson (2013) e Jones et al. (2015) de que a reunião de atributos contábeis, de mercado e macroeconômicos, aliada à modelagens mais modernas, como as RNA, pode produzir melhores resultados na previsão de insolvência, ou, no caso, da recuperação judicial.

Adicionalmente, também no presente trabalho levantou-se a hipótese de que as variáveis de fluxo de caixa seriam mais determinantes na decisão da organização em buscar a RJ como alternativa à insolvência. Uma vez que a superioridade dos modelos propostos já

fora ratificada pelos testes realizados, confirmando parcialmente a hipótese desta pesquisa, resta investigar a relevância dos atributos de fluxo de caixa na RJ.

Para tanto, for a utilizado um teste CFS proposto por Hall (1998); para o autor, bons conjuntos de dados contêm recursos altamente correlacionados com a classe, ainda que não correlacionados entre si.

Em outras palavras, através do teste de correlação (CFS) seria possível identificar quais os atributos – ou variáveis – mais correlacionadas com o resultado da saída da RNA (*output*), no caso, a classificação das organizações que buscam a RJ e o tempo (T) até a ocorrência desse evento. Os resultados obtidos estão representados na Tabela 32:

Tabela 32 – Correlação dos atributos (RJ e T)

Classificação	RJ	T
2	FCF	Giro Ativo
3	FCI	LNIdade
4	IPCA	FCF
5	Selic	FCI
6	LNTam	LNTam
7	Setor	Margem Líquida
8	LNIdade	Setor
9	Margem Líquida	IPCA
10	Giro Ativo	ΔLL
11	ΔRT	Selic
12	ΔLL	ΔRT
13	ΔFCO	ΔFCO
14	FCO sobre LL	FCO sobre LL

Fonte: elaborado pelo autor a partir dos dados do Weka 3.8.3

É possível verificar que, tanto em relação à RJ quanto em relação ao T, dentre os atributos mais correlacionados encontram-se elementos de fluxo de caixa (FCF e FCI) e outros de natureza macroeconômica (IPCA e SELIC) e de mercado (Idade e Tamanho) em detrimento de indicadores exclusivamente de BP, ratificando as evidências de que a conjugação desses dados produz (e modelos menos heterodoxos) produz melhores resultados no campo da previsão de insolvência (Tinoco & Wilson, 2013; Jones et al., 2015).

Em se tratando especificamente da RJ, a posição das variáveis de FCF e FCI também é corroborada pelo trabalho de Dickinson (2011), para quem os fluxos de caixa de financiamento e investimento tem um papel decisivo nas fases de oscilação e declínio das organizações, como é o caso da RJ. No mesmo sentido, o trabalho da autora também pode

explicar a alta correlação do Giro do Ativo com o lapso temporal (T) até a RJ, na medida em que a volatidade do ativo – por meio da alienação de bens e direitos – é um evento comum nas fases de oscilação e declínio e reflete no FCI das organizações.

Já no que toca ao FCO, em ambos os casos esses atributos se mostram pouco correlacionados com o resultado final da rede, ratificando as evidências de que o indicador, quando isoladamente analisado, não se destaca enquanto variável de previsão de insolvência (Casey & Bartczack, 1985).

Por outro lado, a classificação dos indicadores financeiros – de BP e DRE – ao final da Tabela 32 também pode servir para confirmar a hipótese desta pesquisa, no sentido de que as variáveis de fluxo de caixa, macroeconômicas e de mercado, quando aliadas à metodologias menos tradicionais, produzem resultados melhores na previsão de insolvência.

Por fim, a partir da análise dos resultados obtidos, é possível concluir, então, que o modelo proposto – construído por meio da conjugação de informações contábeis, de mercado e de dados macroeconômicos (Tinoco & Wilson, 2013) – é superior aos modelos mais tradicionais, como o LOGIT, corroborando a hipótese aventada neste trabalho, de que existem evidências de que os modelos mais modernos tem melhor performance do que as abordagens tradicionais (Jones et al., 2015), o que inclui não apenas ferramentas estatísticas e de inteligência artificial mais sofisticadas – como as RNA –, como também indicadores menos ortodoxos – como os de fluxo de caixa –, que tem um papel significativo para explicar a insolvência das organizações dentro de seus ciclos de negócios (Drobetz et al., 2017) e, são, portanto, fatores determinantes da RJ.

5. CONSIDERAÇÕES FINAIS

Os dados do indicador Serasa Experian de Falências e Recuperações indicam que o número de pedidos de RJ tem crescido, de forma sistemática, desde a edição da LFR, em 2005 (Serasa, 2018). Embora para Evans e Borders (2014) isso seja um fenômeno mundial, que se acentuou com a crise financeira de 2008, desde há muito que os efeitos deletérios da insolvência das companhias têm estimulado a proliferação de modelos preditivos, principalmente a partir da década de 1960 (Altman, 1968), com os mais diversos resultados (positivos e negativos).

Khashei e Bijari (2010) apontam que a integração de diferentes métodos e indicadores pode ser uma maneira efetiva de aprimorar a capacidade preditiva de modelos de previsão, principalmente em séries temporais.

Nesse contexto, a presente pesquisa contribuiu com o desenvolvimento de um modelo de previsão aprimorado, principalmente por meio da integração diferentes métodos – RNA– e indicadores pouco utilizados pela literatura de referência – elementos de fluxos de caixa, macroeconômicos e de mercado –, mormente em relação a dados brasileiros.

Foram testadas 96 (noventa e seis) RNA diferentes, para identificação do modelo de previsão de RJ que apresentasse os melhores resultados. Ao confrontar os resultados obtidos identificou-se que o modelo proposto possui capacidade classificatória (88,1913%) significativamente superior do que as modelagens mais tradicionais testadas, como a LOGIT (64,13% de acertos na classificação da RJ).

A comparação dos resultados do modelo proposto com as metodologias mais tradicionais é um desafio, na medida em que não pode limitar-se à confrontação da eficácia da capacidade preditiva em contraste com outros modelos estatísticos consagrados para dados brasileiros, como Altman (1968), Elizabetsky (1976), Kanitz (1978) e Matias (1978). Isso porque a análise por meio de RNA apenas ocasionalmente apresenta grande capacidade explicativa (Trippi & Lee, 1996), o que é muito mais corriqueiro nos modelos de análise discriminante e regressão.

Assim, para que a análise dos resultados não se limitasse a mera confrontação dos erros e acertos de previsão, foram analisadas ainda o RMSE (Takacs, 1985; Zumel & Mount, 2014) e a matriz de confusão (Zumel & Mount, 2014) da RNA: os resultados obtidos também demonstram a superioridade do modelo proposto em relação à acurácia (0,323 x 0,47935), sensitividade (87,40% x 21,79%) e eficiência (88,01% x 51,60%) – este último atributo (eficiência) também é superior àquela apresentada pela maioria dos modelos de análise

multivariada no amplo levantamento bibliográfico realizado por Pereira e Martins (2016) no período entre 1930 e 2015, detalhado na Tabela 13.

A partir dos mesmos parâmetros, foi possível identificar os modelos de RNA com melhor coeficiente de relação entre as variáveis selecionadas e o tempo estimado (T) até a organização requerer RJ e a melhor correlação identificada é de 87,85%. A acurácia do modelo proposto também se mostrou superior em relação ao tempo (T) até a RJ, respectivamente de 1,3329 (RNA) e 2,6936 (regressão linear).

Foram realizados testes ainda para identificação da correlação entre os atributos (Hall, 1998) – ou variáveis – e o resultado da saída da RNA (*output*), no caso, a classificação das organizações que buscam a RJ e o tempo (T) até a ocorrência desse evento. Os resultados apresentados demonstram que, para ambos os casos, dentre os atributos mais correlacionados encontram-se elementos de fluxo de caixa (FCF e FCI) e outros de natureza macroeconômica (IPCA e SELIC) e de mercado (Idade e Tamanho) em detrimento de indicadores exclusivamente de BP.

Em função desses resultados foi possível concluir que o modelo proposto é superior aos modelos mais tradicionais, corroborando a hipótese aventada nesta pesquisa de que:

(i) embora o FCO não se destaque, isoladamente, como variável de previsão, consoante já demonstravam Casey e Bartczack (1985), os fluxos de caixa em geral tem um papel significativo para explicar a insolvência das organizações dentro de seus ciclos de negócios (Drobetz et al., 2017) e, são, portanto, fatores determinantes da RJ; e,

(ii) modelos construídos por meio da conjugação de informações contábeis, de mercado e de dados macroeconômicos (Tinoco & Wilson, 2013) apresentam performance superior às abordagens tradicionais (Jones et al., 2015), o que inclui não apenas ferramentas estatísticas e de inteligência artificial mais sofisticadas – como as RNA –, como também indicadores menos ortodoxos, como os fluxos de caixa.

Embora a saída final das RNA raramente tem grande capacidade explicativa, reduzindo-se a sua capacidade de contribuição teórica, o sucesso do modelo deve ser avaliado a partir dos resultados obtidos, que contém significativa contribuição metodológica (Trippi &

Lee, 1996), pois teve-se grande preocupação na definição do evento de interesse que referidos modelos buscam prever.

Em sua grande maioria, os estudos sobre o tema no País, desde o início (Elizabetsky, 1976; Kanitz, 1978; Matias, 1978), restringem-se à previsão da insolvência técnica (Wruck, 1990) ou da falência, não demonstrando grandes preocupações em segregar a RJ como evento de interesse, apesar de poder ser considerada uma fase pré-falimentar. São inúmeros os fatores que justificam a RJ como o evento de interesse a ser investigado pelos modelos de previsão, passando pela renegociação forçada dos créditos (arts. 50 e 58 da LRF), o efeito negativo no *rating* e na precificação dos créditos e até mesmo o tratamento tributário atribuído aos créditos submetidos à RJ (art. 9º, §1º da Lei nº. 9.430/96) e influência (nem sempre positiva) do Judiciário na gestão/administração da organização durante a RJ (Gilson, 1991).

Muito embora a presente pesquisa não tenha contribuído apenas para o aprimoramento da capacidade preditiva dos modelos de previsão de insolvência das organizações, mas também ao permitir a estimação do lapso temporal até a RJ, facilitando a construção de índices e a sua comparação no contínuo, dando consistência às informações coletadas e auxiliando na interpretação dos resultados obtidos (Zhang et al., 1998) para proporcionar soluções gerenciais, de planejamento e de controle (Khashei & Bijari, 2010), ela também contém algumas limitações.

Em se tratando de uma amostra viesada, cujas observações foram obtidas a partir dos dados disponíveis, coletados diretamente junto ao Poder Judiciário, Juntas Comerciais e B3, os resultados não são abrangentes. Além disso, outra dificuldade, no caso, própria das RNA é a compreensão de como as diversas variáveis se comportam dentro da rede, que raramente tem grande capacidade explicativa.

Nada obstante essas limitações, os resultados obtidos contam com inúmeras aplicações para o mercado e a academia, inclusive fomentando pesquisas futuras, na medida em que, como se demonstrou, a RJ é um fenômeno que tem crescido não apenas no Brasil e reflete diretamente nos gestores e investidores.

Novos trabalhos para continuar aprimorando técnicas de previsão, superando as lacunas apontadas, certamente encontrarão o seu lugar, assim como a extrapolação da hipótese desta pesquisa para investigar não apenas o que leva uma companhia a buscar a RJ como alternativa à insolvência, mas também os fatores determinantes para a retomada do seu equilíbrio econômico-financeiro pode se mostrar bastante interessante.

REFERÊNCIAS

Alessandria, G., Choi, H., Kaboski, J. P. & Midrigan, Virgiliu. (2015). Microeconomic uncertainty, international trade, and aggregate fluctuations. *Journal of Monetary Economics*, 69(c), 20-38.

Altman, E. I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy, *The Journal of Finance,* 23(4), 589–609.

_____. (1983). *Corporate financial distress: a complete guide to predicting, avoiding and dealing with bankruptcy*. New York: John Wiley & Sons.

_____. (1984a). A further empirical investigation of the bankruptcy cost question. *The Journal of Finance,* 39(4), 1067-1089.

_____. (1984b). The success of business failure prediction models: an international survey. *Journal of Banking & Finance*, 8(2), 171-198.

Altman, E. I., Baidya, T. K. N. & Dias, L. M. R. (1979). Previsão de problemas financeiros em empresas. Revista de administração de empresas, 19(1), 17-28.

Altman, E. I. & Narayanan, P. (1997). An international survey of business failure classification models. Financial Markets, Institutions and Instruments, 6(2), 1-57.

Andrade, M. E. M. C. & Silva, d. M. (2017). Demonstração dos fluxos de caixa pelo método direto ou indireto?. Revista Mineira de Contabilidade, 18(1), 5-14.

Aysun, U. (2014). Bankruptcy resolution capacity and economic fluctuations. *Journal of Macroeconomics*, 40, 387-399.

Azayite, F. Z. & Achchab, S. (2016). Hybrid discriminant neural networks for bankruptcy prediction and risk scoring. *Procedia Computer Science*, 83, 670-674.

Aziz, A., Emanuel, D.C. & Lawson, G.H. (1988). Bankruptcy prediction - an investigation of cash flow based models. Journal of Management Studies, 25(5), 419-437.

Aziz, M. A. & Dar, H. A. (2006). Predicting corporate bankruptcy: where we stand?. *Corporate Governance*, 6(1), 18-33.

Baird, D. G. (1991). The initiation problem in bankruptcy. *International Review of Law and Economics*, 11(2), 223-232.
Barboza, F., Kimura, H. & Altman, E. (2017). Machine learning models and bankruptcy prediction. *Expert Systems with Applications*, 83, 405-417.

Beaver, W. H. (1966). Financial ratios as predictors of failure. *Journal of Accounting Research*, 4, 71-111.

Bialoskorski Neto, S. Nagano, M. S. & Moraes, M. B. C. (2006). Utilização de redes neurais artificiais para avaliação socioeconômica: uma aplicação em cooperativas. *Revista de Administração da USP*, 41(1), 59-68.

Boettke, P. J. & Coyne, C. J. (2009). Context matters: institutions and entrepreneurship. *Foundations and Trends in Entrepreneurship*, 5(3), 135-209.

Brahmasrene, T, Strupeck, C. D. & Whitten, S. (2004). Examining preferences in cash flow statement format. *The CPA Journal*, 74(10).

Brockett, P. L., Cooper, W. W., Golden, L. L. & Pitaktong, U. (1994). A neural network method for obtaining an early warning of insurer insolvency. *The Journal of Risk and Insurance*, 61(3), 402-424.

Casey, C. & Bartczak, N. (1985). Using operating cash flow to predict financial distress: some extensions. *Journal of Accounting Research*, 23(1), 384-401.

Comitê de Pronunciamentos Contábeis. (2010). *Demonstração dos fluxos de caixa*. São Paulo: Autor.

Constituição da República Federativa do Brasil de 1988 (18a ed.). (1998). São Paulo: Saraiva.

Cox, D. R. & Hinkley, D. V. (1974). *Theoretical statistics*. London: Chapman and Hall.

Crouhy, M., Galai, D. & Mark, R. (2000). A comparative analysis of current credit risk models. *Journal of Banking and Finance*, 24(1-2), 59-117.

Decreto-Lei n. 7.661 (1945, 21 de junho). Lei de Falências. Brasília, DF: Presidência da República.

Dickinson, V. (2011). Cash flow patterns as a proxy for firm life cycle. *The Accounting Review*, 86(6), 1969-1994.
Drobetz, W., Haller, R., Meier, I. & Tarhan, V. (2017). The impact of liquidity crises on cash flow sensitivities. *The Quarterly Review of Economics and Finance*, 66, 225-239.

Elizabetsky, R. (1976). *Um modelo matemático para decisões de crédito no banco comercial.* Dissertação de Mestrado, Escola Politécnica, Universidade de São Paulo, São Paulo, São Paulo.

Evans, J. & Borders, A. L. (2014). Strategically surviving bankruptcy during a global financial crisis: the importance of understanding chapter 15. *Journal of Business Research*, 67(1), 2738-2742.

Fávero, L. P. (2015). *Análise de Dados*. Rio de Janeiro: Elsevier.

Fazzari, S. M., Hubbard, R. G., Petersen, B. C., Blinder, A. S. & Poterba, J. M. (1988). Financing constraints and corporate investment, *Brookings Papers on Economic Activity*, 1, 141-206.

Férnandez, A., Grohéb, S. S. & Uribe, M. (2017). World shocks, world prices, and business cycles: an empirical investigation, *Journal of International Economics*, 108(1), s2-s14.

Financial Accounting Standards Board (2008). *Statement of financial accounting concepts No. 1: objectives of financial reporting by business enterprises*. Norwalk: Autor.

Fitzpatrick, P. J. (1932). A comparison of the ratios of the successful industrial enterprises with those of failed companies. *Certified Public Accountant*, 12, 598-605.

Gilson, S. C. (1991). Managing default: some evidence on how firm choose between workouts and Chapter 11. *Journal of Applied Corporate Finance*, 4(2), 62-70.

Gordon, E. A., Henry, E., Jorgensen, B. N. & Linthicum, C. L. (2017). Flexibility in cash-flow classification under IFRS: determinants and consequences. *Review of Accounting Studies*, 22(2), 839-872.

Govindarajan, V. (1980). The objectives of financial statements: an empirical study of the use of cash flow and earnings by security analysts. *Accounting, Organizations and Society*, 5(4), 383-392.

Hall, M. A. (1998). *Correlation-based Feature Subset Selection for Machine Learning*. Tese de Doutorado. University of Waikato, New Zealand.
Hand, D. J. (2009). Measuring classifier performance: a coherent alternative to the area under the ROC curve. *Machine Learning*, 77(1), 103-123.

Haykin, S. S. (2008). *Neural Networks and Learning Machines*. Toronto: Pearson.

Hosmer, D. W. & Lemeshow, S. (2000). *Applied Logistic Regression*. New York: Wile.

James, H. (2012). *The creation and destructions of value: the globalization cycle*. Cambridge: Harvard University Press.

Jardin, P. D. (2017). Dynamics of firm financial evolution and bankruptcy prediction. *Expert Systems with Applications*, 75(1), 25-43.

Jardin, P. D. & Séverin, E. (2011). Predicting corporate bankruptcy using a self-organizing map: an empirical study to improve the forecasting horizon of a financial failure model. *Decision Support Systems*, 51(3), 701-711.

Jones, S. (2017). Corporate bankruptcy prediction: a high dimensional analysis. *Review of Accounting Studies*, 22(3), 3, 1366-1442.

Jones, S., Johnstone, D. & Wilson, R. (2017). Predicting corporate bankruptcy: an evaluation of alternative statistical frameworks. *Journal of Business Finance & Accounting*, 44(1-2), 3–34.

_____. (2015). An empirical evaluation of the performance of binary classifiers in the prediction of credit ratings changes. *Journal of Banking and Finance*, 56, 72–85.

Kanitz, S. C. (1978). *Como prever falências*. São Paulo: McGraw do Brasil.

Khashei, M. & Bijari, M. (2010). An artificial neural network (p, d, q) model for timeseries forecasting. *Expert Systems with Applications*, 37(1), 479-489.

Kumar, P. R. & Ravi, V. (2007). Bankruptcy prediction in banks and firms via statistical and intelligent techniques – a review. *European Journal of Operational Research*, 180(1), 1-28.

Lei n. 6.404, de 15 de dezembro de 1976. (1976, 15 de dezembro). Dispõe sobre as Sociedades por Ações. Diário Oficial da União, suplemento.

Lei n. 9.430, de 27 de dezembro de 1996. (1996, 27 de dezembro). Dispõe sobre a legislação tributária federal, as contribuições para a seguridade social, o processo administrativo de consulta e dá outras providências. Diário Oficial da União, edição extra.

Lei n. 11.101, de 09 de fevereiro de 2005. (2005, 09 de fevereiro). Regula a recuperação judicial, a extrajudicial e a falência do empresário e da sociedade empresária. Diário Oficial da União, edição extra.

Lei n. 11.638, de 28 de dezembro de 2007. (2007, 28 de dezembro). Altera e revoga dispositivos da Lei no 6.404, de 15 de dezembro de 1976, e da Lei no 6.385, de 7 de dezembro de 1976, e estende às sociedades de grande porte disposições relativas à elaboração e divulgação de demonstrações financeiras. Diário Oficial da União, edição extra.

Lucas, D. J. (1995). Default correlation and credit analysis. *Journal of Fixed Income*, 76-87.

Macedo, M. A. S., Machado, M. A. V., Murcia, F. D. R. & Machado, M. R. (2011). Análise do impacto da substituição da DOAR pela DFC: um estudo sob a perspectiva do value-relevance. *Revista Contabilidade & Finanças*, 22(57), 299-318.

Maciel, F. F. S. (2015). *Escolhas contábeis na demonstração dos fluxos de caixa no contexto do mercado de capitais brasileiro*. Dissertação de Mestrado, Faculdade de Economia, Administração e Contabilidade, Universidade de São Paulo, São Paulo.

Matias, A. B. (1978). *Contribuição às técnicas de análise financeira: um modelo de concessão de crédito*. Dissertação de Mestrado, Faculdade de Economia, Administração e Contabilidade, Universidade de São Paulo, São Paulo.

Obermann, L. & Waack, S. (2015). Demonstrating non-inferiority of easy interpretable methods for insolvency prediction. *Expert Systems with Applications*, 42(23), 9117-9128.

Ohlson, J. A & Aier., J. K. (2009). On the analysis of firms' cash flows. *Contemporary Accounting Research*, 26(4), 1091-1114.

Ohlson, J. A. (1980). Financial ratios and the probabilistic prediction of bankruptcy. *Journal of Accounting Research*, 18(1), 109-131.

Organização de Cooperação e de Desenvolvimento Econômico. (2017). *Entrepreneurship at glance*. Paris: Autor.

Pereira, V. S. & Martins, V. F. (2015). Estudos de previsão de falências – uma revisão das publicações internacionais e brasileiras de 1930 a 2015, *Revista de Contabilidade Contemporânea*, 12(26), 163-196.

Salotti, B. M. & Yamamoto, M. M. (2007). Os métodos de divulgação da demonstração dos fluxos de caixa no Brasil. *Revista Universo Contábil*, 3(3), 25-37.

Robinson, D. T. & Sensoy, B. A. (2016). Cyclicality, performance measurement, and cash flow liquidity in private equity. *Journal of Financial Economics*, 122(3), 521-543.

Rosa, P. S. & Gartner, I. R. (2018). Financial distress in Brazilian banks: an early warning model. *Revista Contabilidade & Finanças*, 29(77), 312-331.

Serviço Brasileiro de Apoio às Micro e Pequenas Empresas. (2014). *Causa mortis: o sucesso e o fracasso das empresas nos primeiros 5 anos de vida*. Brasília: Autor.

Scabora, F. C. (2018). A recuperação judicial do produtor rural. In T. Damian (Org.). *O Direito frente às novas demandas da sociedade* (pp. 93-113). Jundiaí, SP: Paco Editorial.

Scherer, L. M., Teodoro, J. D. Kos, S. R. & Anjos, R. P. (2012). Demonstração dos fluxos de caixa: análise de diferenças de procedimentos de divulgação entre empresas listadas nas bolsas de valores de São Paulo, Frankfurt, Milão e Londres. *Revista de Contabilidade e Controladoria*, 4(2), 37-51.

Serasa. (2018). *Serasa Experian de Falências e Recuperações*. São Paulo: Autor.

Silva, D. M., Martins, V. A. & Lima, F. G. (2014). Escolhas contábeis na evidenciação da demonstração dos fluxos de caixa. In *XXXVIII Encontro da Associação Nacional de Pós-Graduação e Pesquisa em Administração*, Rio de Janeiro, RJ.

Stam, H., Hartog, C. Stel, A. V. & Thurik, R. (2011). Ambitious entrepreneurship, high-growth firms, and macroeconomic growth. In Minniti, M. *The dynamics of entrepreneurship: evidence from global entrepreneurship monitor data*. Oxford: University Press.

Sweeney, D. J. Williams, T. A. & Anderson, D. R. (2013). *Estatística aplicada à administração e economia*. São Paulo: Cengage Learning.

Takacs, L. A. (1985). A two-step scheme for the advection equation with minimized dissipation and dispersion errors. *Monthly Weather Review*, 113, 1050-1065.

Teixeira, T. (2012). Recuperação judicial de empresas. *Revista da Faculdade de Direito da Universidade de São Paulo*, 106/107, 181-214.

Theil, H. (1969). On the use of information theory concepts in the analysis of financial statements. *Management Science*, 15(9), 459-480.

Thomas, L. C., Ho, J. & Scherer, W. T. (2001). Time will tell: behavioural scoring and the dynamics of consumer credit assessment. *IMA Journal of Management Mathematics*, 12(1), 89-103.

Thompson, J. H. & Buttross, T. E. (1988). Return to cash flow. *The CPA Journal*, 30-40.

Tinoco, M. H. & Wilson, N. (2103). Financial distress and bankruptcy prediction among listed companies using accounting, market and macroeconomic variables. *International Review of Financial Analysis*, 30, 394–419.

Trippi, R. R. & Lee, J. K. (1996). *Artificial intelligence in finance & investing: state-of-the-art technologies for securities selection and portfolio management*. Chicago: Irwin.

Wang, L., Zeng, Y. & Chen, T. (2015). Back propagation neural network with adaptive differential evolution algorithm for time series forecasting. *Expert Systems with Applications*, 42(2), 855–863

Wang, M., Chen, H., Li, H., Cai, Z., Zhao, X., Tong, C., Li, J. & Xu, X. (2017). Grey wolf optimization evolving kernel extreme learning machine: application to bankruptcy prediction. *Engineering Applications of Artificial Intelligence*, 63, 54-68.

Wennekers, S., & Thurik, R. (1999). Linking entrepreneurship and economic growth. *Small Business Economics*, 13(1), 27–55.

Wruck, K. (1990). Financial distress, reorganization, and organizational efficiency. *Journal of Financial Economics*, 27(2), 419-444.

Yu, Q., Miche, Y., Séverin, E. & Lendasse, A. (2014). Bankruptcy prediction using extreme learning machine and financial expertise. *Neurocomputing*, 128, 296-302.

Zhang, G., Patuwo, B. E. & Hu, M. Y. (1998). Forecasting with artificial neural networks: the state of the art. *International Journal of Forecasting*, 14(1), 35-62.

Zhanga, G., Hub, M. Y., Patuwob, B. E. & Indro, D. C. (1999). Artificial neural networks in bankruptcy prediction: general framework and cross-validation analysis. *European Journal of Operational Research*, 116(1), 16-32.

Zumel, N. & Mount, J. (2014). *Practical data science with R*. New York: Manning.