

Artificial Intelligence para Previsão de Insolvência Corporativa: uma revisão de literatura

DENIZE LEMOS DUARTE

UNIVERSIDADE FEDERAL DE UBERLÂNDIA (UFU)

FLAVIO LUIZ DE MORAES BARBOZA

UNIVERSIDADE FEDERAL DE UBERLÂNDIA (UFU)

***Artificial Intelligence* para Previsão de Insolvência Corporativa: uma revisão de literatura**

1. INTRODUÇÃO

Com o rápido desenvolvimento nos sistemas de informação e a acelerada disseminação da globalização econômica, a forma de se conduzir uma avaliação eficaz do risco de crédito é uma questão de suma importância no campo de finanças. O efeito do elevado índice de insucessos empresariais pode ser devastador para investidores, acionistas, fornecedores, sociedade e de forma geral, para a economia de um país (GENG; BOSE, 2015; ZELENKOV et al., 2017; ALAKA et al., 2018). Uma reduzida melhora na precisão da previsibilidade de *financial distress* pode proporcionar maiores retornos, minimizar os efeitos negativos na disfunção do sistema, nos segmentos de mercado e até mesmo no crescimento econômico.

Diante do efeito oneroso do *financial distress*, nas últimas décadas, os mercados se mostram receosos com a concessão de crédito e com a própria fragilidade do sistema financeiro como um todo (ADNAN AZIZ; DAR, 2006). Em 2004 o Comitê de Basileia de Supervisão Bancária (CBSB) divulgou a revisão do Acordo de Capital da Basileia, conhecido como Basileia II, com a finalidade de alcançar uma medida mais precisa dos riscos incorridos. Essa versão, juntamente com as anteriores e outras questões adicionais sobre risco de mercado e de crédito, passou a tratar também o risco operacional (BIS, 2019; BACEN, 2019).

Após a crise financeira global de 2008, o BCBS efetuou diversas alterações na exigência de capital para risco de mercado e nas determinações relacionadas ao apreçamento de instrumentos financeiros. Essas diretrizes objetivaram aperfeiçoar a capacidade dos bancos de absorver choques e enfrentar eventuais crises financeiras (BIS, 2019; BACEN, 2019). Com isso surgiu o Basileia III, que abrange as medidas que fortalecem a regulação, supervisão e a gestão de risco no setor bancário (BIS, 2019; BACEN, 2019).

Neste contexto, existe a necessidade de se quantificar e interpretar as variáveis e informações referentes ao fenômeno de *financial distress* que envolve o risco de crédito e suas operações. Existem diversos estudos de métodos estatísticos, baseados em regressões, análises discriminantes multivariadas e baseados em *Artificial Intelligence* (AI) disponíveis, mas não existe uma concordância daquele que traz a melhor estratégia, maior assertividade e precisão diante do fenômeno da insolvência (ADNAN AZIZ; DAR, 2006; ABDU; POINTON, 2011). Ohlson (1980) utilizou a regressão logística para a estimação do padrão de probabilidade do mutuário potencial. Beaver (1966), Altman (1968), Taffler (1982) e Altman, Marco e Varetto (1994) usaram a *Multiple Discriminate Analysis* (MDA) através de indicadores contábeis e financeiros. Altman (1979) utilizou a análise discriminante para classificar e prever problemas financeiros em empresas brasileiras. Destacaram-se também outros estudos de análise discriminante e regressão logística (MARTIN, 1977; GRIFFIN; LEMMON, 2002; HILLEGEIST; KEATING; CRAM; LUNDSTEDT, 2004; DE ANDRES; LANDAJO; LORCA, 2005). Begley, Ming e Watts (1996) criticaram os modelos apresentados por Altman (1968) e por Ohlson (1980), sendo que este último apresentou, nesta análise, melhor desempenho. Alguns estudos utilizaram algoritmos e inteligência artificial para classificar a idoneidade creditícia e a previsibilidade de *financial distress* ou falência (TAM; KIANG, 1992; ALTMAN; MARCO; VARETTO, 1994; SHIN; LEE; KIM, 2005; MIN; LEE, 2005; PAN, 2012; OLSON; DELEN; MENG, 2012; KRUPPA; SCHWARZ; ARMINGER; ZIEGLER, 2013; SUN; LI; HUANG; HE, 2014; PAL; KUPKA; ANEJA; MILITKY, 2016; BARBOZA; KIMURA; ALTMAN, 2017; SUN; LANG; FUJITA; LI, 2018; GARCÍA; MARQUÉS; SÁNCHEZ, 2019). Addo, Guegan e Hassani (2018) discorrem que os algoritmos baseados em redes neurais artificiais não fornecem necessariamente o melhor desempenho e que é importante fazer verificações na qualidade dos dados para evitar vieses na classificação.

Assim, como os estudos sobre risco de crédito dividem opiniões, devido a evidência de resultados contraditórios e considerando a importância na gestão da incerteza e de riscos, na maximização da riqueza dos acionistas, na circulação corrente de recursos na economia e consequentemente no crescimento e maior estabilidade econômica de um país, o problema que estimulou a realização deste estudo foi: como se apresenta o desempenho das características e das condições de desenvolvimento das literaturas relacionadas ao risco de crédito?

Desse modo, este estudo adotou uma perspectiva para avaliar as diversas pesquisas acadêmicas com as múltiplas visões sobre risco de crédito com enfoque em *financial distress* (FD), classificação de crédito, falência e *Artificial Intelligence* (AI) e, sua evolução ao longo dos anos, realizando uma revisão sistemática para identificar os diferentes construtos desse campo da literatura.

Para desenvolvimento deste trabalho empregou-se a metodologia *Knowledge Development Process-Constructivist* (ProKnow-C), o que resultou, como suporte empírico, uma seleção de 165 publicações científicas nacionais e internacionais mais relevantes. Diante desta averiguação, pode-se afirmar que a aplicação da tecnologia computacional no âmbito de análise da gestão do risco de crédito, vem angariando atenção de forma singular. Constatou-se que a demanda para se identificar e introduzir novas variáveis, classificadores e métodos mais assertivos de forma conjunta com a análise fundamentalista, é constante. O esforço, para se aprimorar a interpretação dos dados e modelos, é intenso e procuram tratar as lacunas neste campo de estudos. Desta forma, este estudo contribui para a categorização das linhas de pesquisas e traz uma síntese da literatura, em que os resultados servirão como referência, além de sugerir pesquisas futuras sobre o tema. As revisões de literatura constituem um arcabouço de publicações com contribuições relevantes e lacunas referente a áreas do conhecimento.

Este artigo está organizado em cinco seções além desta introdução. A seção 2 trata do risco de crédito e sua relação com os modelos e técnicas computacionais. A seção 3 traz a metodologia utilizada nesta pesquisa. A seção 4 aborda uma discussão sobre os resultados e desafios sobre o tema. Por fim, a seção 5 apresenta as considerações finais.

2. LITERATURA E ABORDAGEM GERAL

O risco de crédito tem sido foco de estudos há décadas e se trata de um importante tema na área de gestão financeira. Beaver (1966) estuda os índices financeiros como preditores de dificuldades financeiras usando uma perspectiva *Bayesian*, que trata a avaliação de hipóteses probabilísticas por razões de verossimilhança, onde os eventos possíveis são vistos como sendo dicotômicos, onde a empresa sofre dificuldades financeiras ou não. O autor concluiu que a relação entre a razão de verossimilhança e o fluxo de caixa para a dívida total foi o melhor preditor da taxa única.

Altman (1968) usou Análise Discriminante Multivariada para classificar as empresas falidas e não falidas para prever o fenômeno de falência e concluiu que a falência pode ser prevista com precisão até dois anos antes da falha real através da combinação de índices contábeis e financeiros. Altman (1983) examinou as influências das condições macroeconômicas sobre o insucesso empresarial e constatou que a propensão ao fracasso da empresa é aumentada devido aos efeitos cumulativos do crescimento econômico real reduzido, do desempenho do mercado de ações, do crescimento da oferta monetária e do aumento da formação de empresas. Ohlson (1980) aplicou modelos de Regressão Logística para prever dificuldades financeiras. Zmijewski (1984) usou um modelo *probit* para previsão de falência.

Muitas são as metodologias utilizadas para auxiliar e melhorar a precisão na previsão do risco de crédito. Adnan, Aziz e Dar (2006) discorrem sobre os métodos como sendo: métodos estatísticos tradicionais e os modelos baseados em AI, que podem ser univariados ou multivariados, que se concentram em indícios que levam a falha da organização e os dados são extraídos principalmente de relatórios financeiros e contábeis; os modelos teóricos se

concentram nas causas qualitativas da falha, e extraem informações que podem argumentar a falha utilizando a teoria multivariada e empregando técnicas estatísticas para fornecer o suporte quantitativo para o argumento teórico.

Os modelos de aprendizado de máquina, que emergem da AI, estão amplamente sendo aplicados devido ao seu bom desempenho de predição, eles tem a capacidade de capturar a relação de não-linearidade existente nos dados (HUANG; TZENG; ONG, 2006; ZHAO et al., 2016; ZHU et al., 2016).

O aprendizado de máquina envolve o estudo da teoria do reconhecimento de padrões, a construção de algoritmos e aprendizagem computacional em AI, que pode treinar, aprender e fazer predições sobre determinados dados (ZHU et al. 2016). Em 1992, Tam e Kiang (1992) usaram uma abordagem de rede neural comparando outros modelos. Eles selecionaram 59 bancos em crise e 59 bancos em situação normal no mercado americano entre 1985 e 1987, com base em 19 índices financeiros e comparam quatro modelos diferentes, como ANN, MDA, Logit e DT. De acordo com seus experimentos, a ANN e a DT tiveram melhor desempenho preditivo. Os resultados empíricos destes estudos foram promissores para a avaliação das condições financeiras das empresas em termos de precisão preditiva usando a ANN.

Tam e Kiang (1992) discorrem que uma *Artificial Neural Networks* (ANN) representa uma função discriminante não-linear como um padrão de conexões entre suas unidades de processamento. Huang, Tzeng e Ong (2006) comentam que as ANN foram desenvolvidas para simular a neurofisiologia do cérebro humano como um tipo de modelo de regressão não linear flexível, discriminante e de agrupamento. Os autores afirmam que a arquitetura da ANN pode ser representada como um sistema de três camadas, sendo uma de entrada, que processa os recursos, a outra de ocultação, com pesos adequados usando função de ativação como tangente hiperbólica, softmax ou função logística e a última saída de camadas.

Brockett et al. (1994) ponderam que um modelo de rede neural pode evoluir e se adaptar conforme os dados, sistemas ou problemas vão se modificando, e esta característica não pode ser encontrada em outros modelos estáticos. Assim, muitos trabalhos baseados em ANN, SVM e outros algoritmos geralmente se encaixam bem nos dados para tratar a previsão de FD e falência, mas devido à sua complexidade, eles são considerados como tecnologias “*black box*” (OLSON et al., 2012).

E ainda para se melhorar a precisão na predição do risco de crédito, muitas pesquisas utilizam combinações de técnicas e classificadores que integram os diversos métodos, fazendo comparações entre eles. Essa combinação de classificadores, técnicas e métodos tem trazido melhor desempenho tanto de predição, quanto na redução dos erros Tipo I e II (WANG; MA, 2012; MARQUÉS; GARCÍA; SÁNCHEZ, 2012; HAJEK; OLEJ; MYSKOVA, 2014; LESSMANN; BAESENS; SEOW; THOMAS, 2015; ABELLÁN; CASTELLANO, 2017; DU JARDIN, 2017; DU JARDIN, 2018).

3. METODOLOGIA

A fim de abordar o objetivo estabelecido para este estudo, realizou-se uma revisão sistemática da literatura sobre análise de risco de crédito, falência, FD e *machine learning* (ML) em artigos publicados no mundo. A revisão bibliométrica é definida como uma aplicação matemática e estatística de métodos para tratar temas diversos oriundos de vários meios de comunicação (PRITCHARD, 1969).

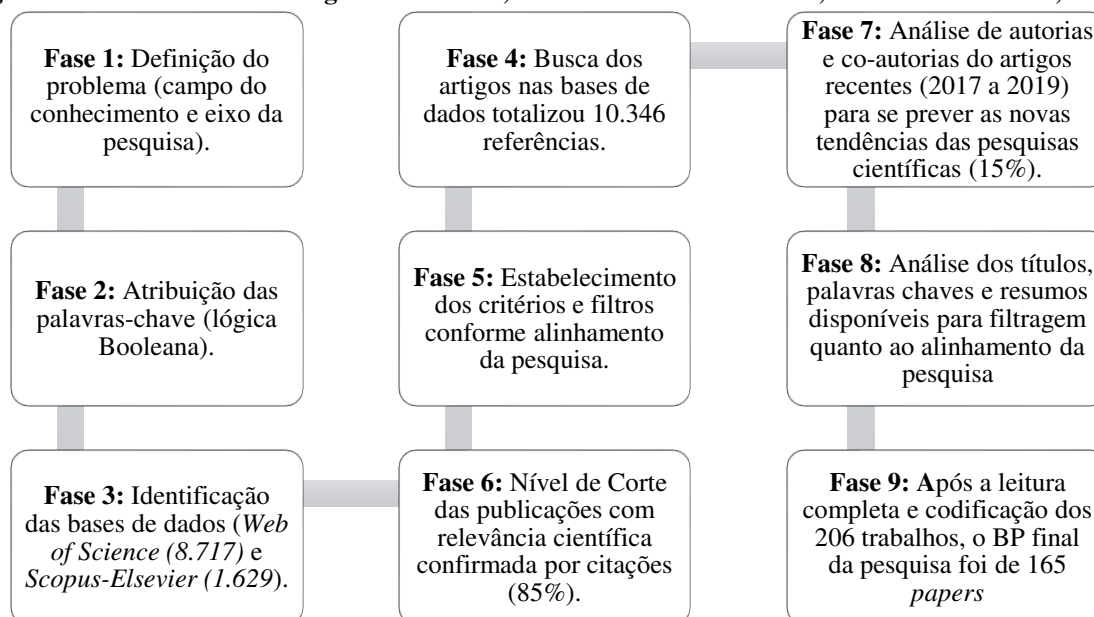
Para realização deste trabalho, seguiu-se a orientação do processo para formação do conhecimento e triagem dos artigos sobre o tema pelo método *Knowledge Development Process-Constructivist* (ProKnow-C), proposto por e De Azevedo, Ensslin e Jungles (2014) e Ensslin et al. (2017), que fornece uma análise de processos de forma estruturada para construir um arcabouço teórico robusto e consistente. Este método se baseia na delimitação do campo do conhecimento, na seleção das bases de dados, das palavras-chave, de filtros temporais e critérios

para inclusão e exclusão de pesquisas que estão desalinhadas ao que concerne o tema central deste estudo, citações, co-citações, autorias, co-autorias e análise de periódicos.

Foram então atribuídas as palavras-chave que conduzirão a busca pelo referencial para formar o *Bibliometric Portfolio* (BP): "bankruptcy" or "business failure" or "corporate governance" or "credit risc" or "credit scoring" or "expouse at default" or "financial distress" or "loss given default" or "probability of default" or "rating" or "risk of default" e "machine learning" or "artificial intelligence" or "suport vector machine" or "genect algorithm" or "boosting" or "bagging" or "data mining" or "ensemble".

A Figura 1 apresenta o resumo do processo de seleção dos *papers* para a construção do referencial teórico deste trabalho (BP).

Figura 1 - Resumo da metodologia ProKnow-C, similar a De Azevedo et al., 2014 e Ensslin et al., 2017



Fonte: Elaborado pelos autores.

Para avaliação, medição e interpretação dos resultados foram realizadas análises quantitativas sobre o *Bibliometric Portfolio* (BP) (WANG; VEUGELERS; STEPHAN, 2016).

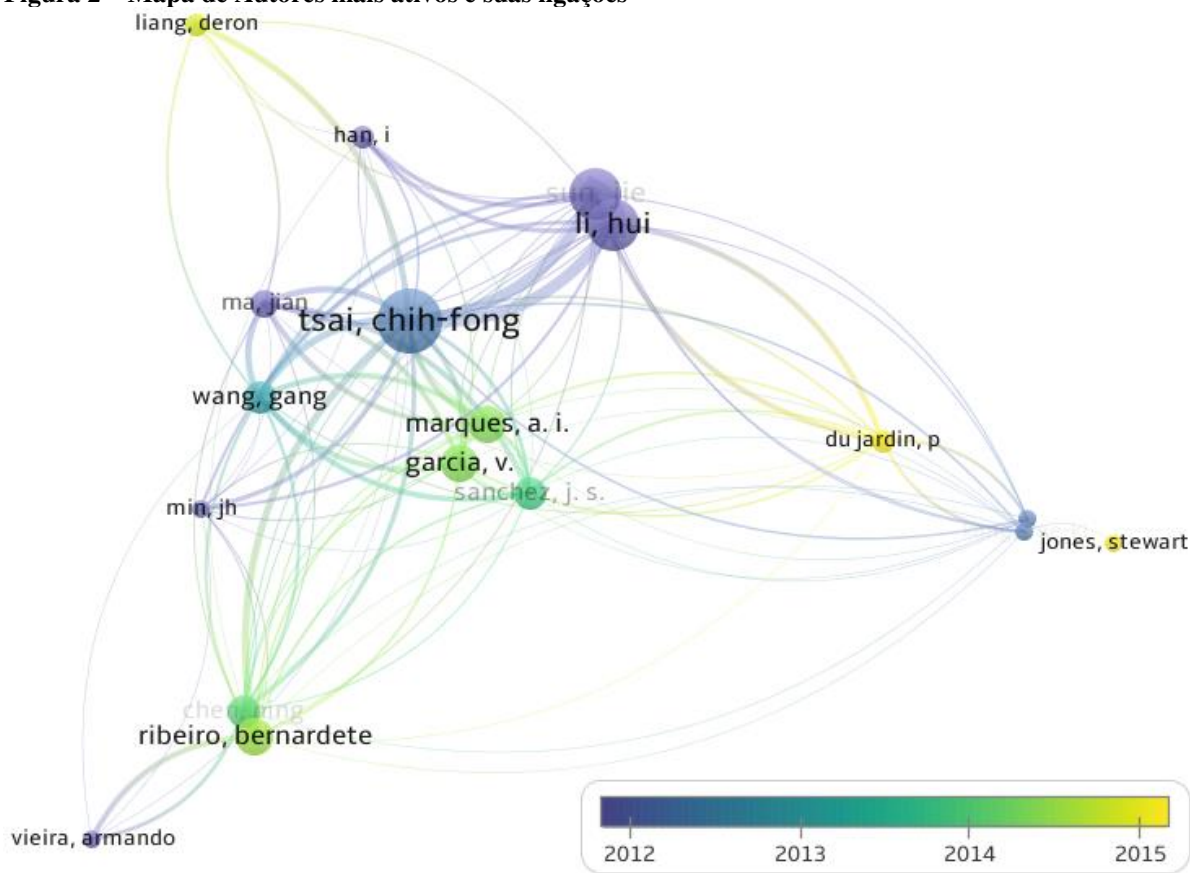
4. RESULTADO DAS PESQUISAS

No levantamento de artigos que conduziu este estudo segundo a metodologia ProKnow-C, constatou 165 trabalhos relacionados à aplicação dos métodos de AI, ML e *Artificial Neural Networks* (ANN) para tratar FD, risco de crédito, falência e *Default* corporativo. Esse acervo englobou um total de 302 pesquisadores distintos. Entre eles, 55 autores publicaram mais de um *paper* em relação ao tema desta pesquisa.

Sobre os autores que mais publicaram, o autor Chih-Fong Tsai é o mais ativo, com 13 trabalhos publicados (citações 1.259), Hui Li e Jie Sun ficam em segundo lugar com 10 trabalhos cada (747 citações cada um). Em Terceiro lugar, com 7 estudos publicados sobre o tema desta pesquisa ficam Vicente García, Ana I. Marqués, J. Salvador Sánchez e Bernardete Ribeiro (319 citações cada um).

A Figura 2 apresenta os 15 autores mais dominantes ativamente e suas ligações. Pode-se notar que os autores Vicente García, Ana I. Marqués, J. Salvador Sánchez apesar de serem de Universidades distintas sempre publicam trabalhos conjuntamente. Os autores Hui Li e Jie Sun, neste BP, todos os trabalhos foram publicados conjuntamente. Os autores Bernardete Ribeiro e Armando S. Vieira estão sempre publicando como autores e co-autores.

Figura 2 – Mapa de Autores mais ativos e suas ligações



Fonte: VOSviewer – Resultados da pesquisa.

O autor Chih Fong Tsai de Taiwan é o mais citado entre os autores mais ativos, pois ele foi precursor ao estudar o tema. Seus artigos tratam de modelos híbridos, que utilizam combinações de técnicas de conjuntos classificadores para previsão de FD, falência e para prever o risco de crédito. Hui Li, da China, é especialista em ML, redes neurais e data mining. Desenvolve modelos híbridos com *case based reasoning* e que também utilizam combinações de técnicas de conjuntos classificadores para previsão de FD e risco de crédito. Em um dos artigos selecionados no BP, o autor propõe uma abordagem *Elimination And Choice Net Translating Reality-ELECTRE* (LI e SUN, 2009). Os autores e co-autores que mais foram citados em relação ao tema desta pesquisa por ordem de citações e publicações respectivamente, são: Varetto, F (1617-2), Kiang, MY (1444-1), Tam, KY (1444-1), Altman, E (1393-2), Marco, G (1336-1), Tsai, CF (1259-13), Shin, KS (1110-2), Lee, YC (1052-3), Han, I (1031-4).

Para se medir a relevância dos periódicos do BP, foram considerados os indicadores de classificação JCR, para comparação direta com os periódicos da área de conhecimento assim priorizou a classificação por este índice, (JCR, 2019) e o SJR, para se comparar com outros periódicos referentes a outras áreas do conhecimento (SCIMAGO, 2018). Os *papers* deste BP foram publicados em 44 periódicos distintos, sendo que os 4 mais importantes, neste sentido, são: *Ieee Transactions on Fuzzy Systems* (8415, 2,794), *Information Fusion* (6639, 2,238), *Tourism Management* (5921, 2,924) e o *Ieee Transactions on Systems Man Cybernetics-Systems* (5135, 2,147).

A tabela 1 traz numericamente a distribuição do BP entre os periódicos. Pode-se verificar que as publicações nos periódicos mais bem avaliados estão voltadas para estudos empíricos de construção e comparabilidade de modelos e técnicas computacionais para previsão e gestão do risco de crédito.


Tabela 1 – Journals com mais publicações e citações do BP

Journal	Publicações	Citações	Média Citações/Publ.	% partic. Cit.	JCR	SJR
Expert Systems With Applications	57	8.193	144	35%	3.768	1,190
Decision Support Systems	9	2.863	318	12%	3.565	1,536
Knowledge-Based Systems	15	2.155	144	9%	4.396	1,460
European Journal of Operational Research	14	2.110	151	9%	3.428	2,205
Journal of Banking & Finance	3	1.671	557	7%	1.931	1,599
Management Science	1	1.444	1.444	6%	3.544	6,080
Applied Soft Computing	8	576	72	2%	3.907	1,216
Others	58	4.345	75	19%		
Total	165	23357	142	100%		

Fonte: Resultado da pesquisa.

A figura 3 traz o mapeamento por país de origem das pesquisas deste BP, que contemplou 34 países distintos, referente as instituições em que os autores são associados, determinando a procedência esses trabalhos. Os países com maior densidade no mapa (Figura 5) mostram onde se concentra o maior volume pesquisas, que são China (33), Taiwan (30), USA (20), Espanha (14) e Coreia do Sul (13), o que representa 67% do BP.

Figura 3 – Mapa de publicações por país de procedência



Fonte: VOSviewer – Resultados da pesquisa

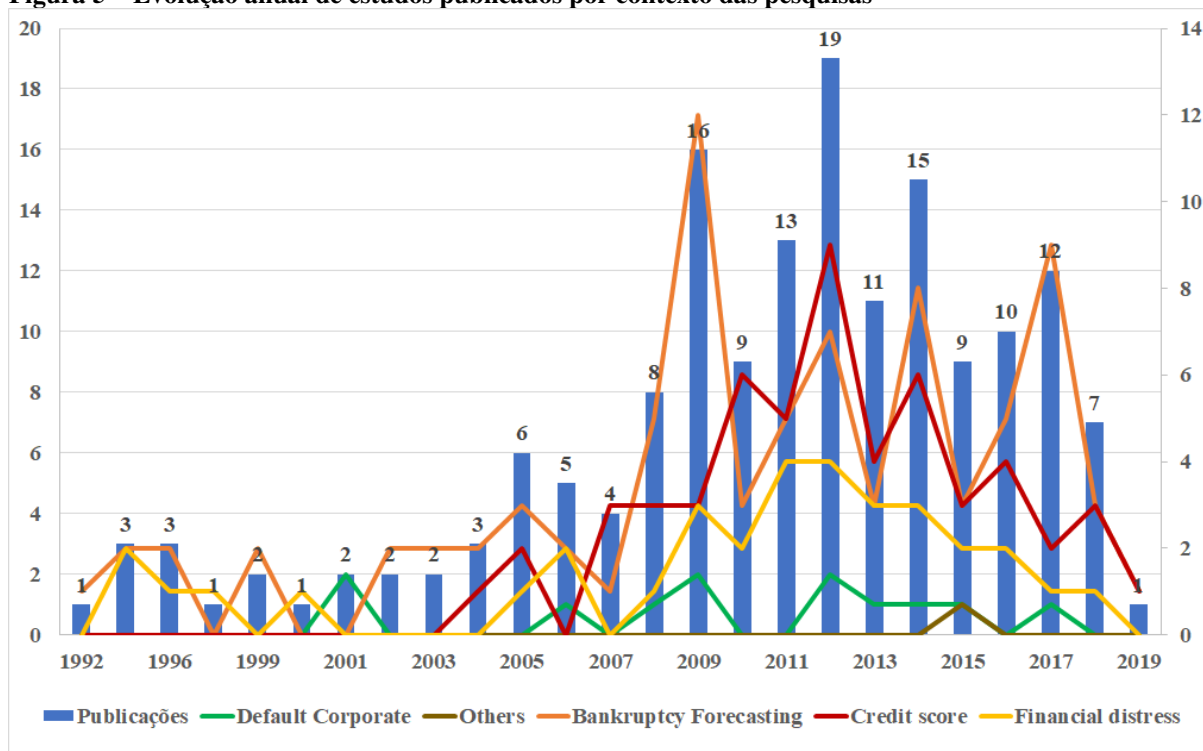
Ao contrário, as regiões com menor densidade no mapa, são as que apresentam menor número de pesquisas em relação ao tema central deste BP, que são: Países de Gales, Suíça, África do Sul, Cingapura, Escócia, Rússia, Irlanda do Norte, Irã, Grécia, Finlândia, Dinamarca e Brasil, onde cada uma produziu apenas 1 *paper* com relevância científica. Os estudos que contemplam pesquisadores dessas regiões e de outras, onde não houve nenhum *paper* relacionado ao tema central deste trabalho, como países da América Latina, Israel, Hungria entre outros, poderiam trazer enriquecimento ao acervo de pesquisas com resultados distintos e múltiplas visões. Em destaque de grandeza de citações tem-se os autores dos USA (5.880), Taiwan (4.421), China (2.730), Coreia do Sul (2.388) e Itália (1.801), o que representa 71% de participação em relação ao total.

A Figura 4 classifica as *key words* dos *papers* que fazem parte deste BP. É possível constatar que as palavras que mais se destacaram foram: *neural network* (97), *bankruptcy*

Network), (GA-Genetic Algorithm), (RS-Random Subspace), (RBF-Radial Basis Function), (CBR-Case Based Reasoning), (RST-Rough Set Theory), (SOM-Self Organizing Map), (RTF-Rotation Forest), (ELM-Extreme Learning Machine), (ML-Machine Learning), (SMO-Sequential Minimal Optimization), (O-Others); 4 - Focus: (A-Financial Institution); (B-Non-Financial Institutions), (C-Others); 5 - Country of origin of data: (A-USA), (B-Europe), (C-Asia), (D-Latin America), (E-Australia), (F-Other / Not Mentioned); 6 - Dependent variables: (A-Bankruptcy), (B-Financial distress), (C-Default), (D-Loss Given default), (E-Others); 7 - Independent variables: (A-Financial Ratios), (B-Non-Financial Indices), (C-Personal information), (D-Others); 8 - Time horizon (database): Start, End.

A Figura 5 demonstra a evolução quantitativa de *papers* publicados anualmente diante de cada contexto no PB. Nota-se que houve um aumento considerável de artigos publicados após o ano de 2008, o que pode ser explicado pela crise financeira ocorrida em meados de 2007/2008, também pela melhoria na infraestrutura e evolução dos recursos computacionais, que são capazes de armazenar e transacionar uma vasta quantidade de dados, bem como o aperfeiçoamento dos métodos de AI (MORO; CORTEZ; RITA, 2015). Cole e Eales (1917) descrevem sobre a questão de muitas pesquisas serem concentradas em um período específico e em uma determinada região, por mais indiferente que sejam, esta é uma indicação segura do atendimento aos interesses e atividades contemporâneos. Os autores completam ainda que, pode-se traçar os ramos do assunto que estavam atraindo maior atenção naquele determinado momento, e que a influência foi exercida pelos trabalhos mais importantes publicados.

Figura 5 – Evolução anual de estudos publicados por contexto das pesquisas



Fonte: Resultados da pesquisa.

Reforça-se então, a importância do tema, que explora os mecanismos de *machine learning* em *financial distress* das organizações. Os anos que tiveram a maior quantidade de publicações foram 2009, 2012 e 2014, sendo 16, 19 e 15 publicações respectivamente. A média de publicações nos últimos 6 anos foi de 10 publicações sendo o menor número em 2018 com 8 publicações, desconsiderando o ano corrente de 2019.

As variáveis de interesse que tratam do contexto dos trabalhos, foram classificadas e agrupadas, e percebeu-se que a maior parte dos estudos, 83 (45%), procuram identificar o

behavior das empresas que entraram em falência em relação as empresas que não faliram. Já os modelos que criam score e classificam o risco foram 55 *papers* (28%) e 34 trabalhos (18%) procuraram prever o FD das organizações. Dentro do próprio ciclo de vida da organização ela passa por fases de dificuldades financeiras, quando esta não está totalmente estabilizada para comportar tais eventos, o desfecho pode resultar em falência ou recuperação judicial, por isso, a precisão na previsão dessas ocorrências para os tomadores de decisão e demais envolvidos é de extrema relevância e contribui para que a situação não se torne ainda mais grave, aumentando o número de falhas e se tornando um processo contagioso e devastador para a economia de uma país (ALTMAN; BAIDY; DIAS, 1979; GENG; BOSE, 2015; ZELENKOV et al., 2017; ALAKA et al., 2018).

No que tange ao *Reserach type* a maior parte dos trabalhos são estudos empíricos (152), cerca de 93,3% e o restante, 11 *papers* (67%), tratam de revisão de literatura. Os trabalhos do BP desenvolvem modelos utilizando da tecnologia moderna para simplificar processos e aumentar a eficiência na precisão dos modelos de previsão baseados em padrões, procurando gerenciar de maneira proativa o risco de crédito, as dificuldades financeiras e as falências corporativas (GARCÍA; MARQUÉS; SANCHÉZ, 2019).

Uma situação importante para se destacar entre os modelos computacionais seria a interface com a análise financeira qualitativa para se explicar melhor e facilitar a implementação e teste dos modelos construídos (HAJEK; OLEJ; MYSKOVA, 214). A análise financeira qualitativa poderia atender as perspectivas regionais e condições regulatórias, os estudos de Ribeiro, Chen e Kovacec (2017) trazem uma abordagem baseada em algoritmo para construção de gráficos, utilizando relações binárias de dados qualitativos de risco de crédito, e os resultados demonstram que o desempenho da precisão de previsibilidade pode ser melhorado.


Os *papers* dos BP focaram em trabalhar, em sua maioria (81%), usando conjunto de dados de empresas não financeiras, 13% utilizaram dados de financeiras ou seguradoras e o restante, 8%, não foi possível identificar. Cada segmento apresenta um sistema contábil e regulatório específico, é um segmento de mercado distinto, portanto faz-se necessária essa especificação, e para filtrar ainda mais este BP, optou-se, nesta pesquisa, por excluir estudos com conjuntos de dados de pessoas físicas (exemplo de artigo desconsiderado: GUO; ZHOU; LUO; LIU; XIONG, 2016). Dentre os *papers* que não possuíam esta informação estão Hu (2009) e Lahsasna, Ainon e Teh (2010).

Para se prever com precisão o FD e a falência das organizações, vários métodos foram desenvolvidos e testados. Eles podem ser divididos nas seguintes categorias: métodos estatísticos tradicionais e métodos baseados em AI. Os métodos estatísticos tradicionais funcionam bem e são mais simples e compreensíveis. Os modelos baseados em redes neurais artificiais, máquinas de vetores de suporte e outros algoritmos, geralmente apresentam desempenho superior e se encaixam de forma satisfatória na base de dados para a previsibilidade, mas devido à complexidade dos métodos e à falta de compreensão de analistas e gestores, os modelos são considerados tecnologias *black box* (OLSON et al., 2012). Os métodos e técnicas mais utilizados no BP são: SVM-Support Vector Machine (10,4%), LR-Logistic Regression (10,4%), ANN-Artificial Neural Networks (10,1%), BA-Bagging (4%), LDA-Linear Discriminant Analysis (3,9%), MLP-MultiLayer Perceptron (3,7%), MDA-Multiple Discriminant Analysis (3,7%), DT-Decision Tree (3,6%). Embora existam múltiplos métodos para previsão de FD e falência, eles se comportam de maneira diferente em várias situações, conforme a base de dados e as variáveis selecionadas. Assim, não é possível especificar um único método apropriado que possa se adaptar e funcionar melhor que qualquer outro (WANG; CHEN; CHU, 2018).

Ao se classificar as variáveis explicativas, a maioria dos estudos (77%) utilizam indicadores financeiros e contábeis, pela facilidade de apurar e trabalhar com os dados. As

experimentos podem levar a conclusões distorcidas e talvez não atendam as demandas dos diversos mercados, pois os fatores que afetam a falência variam entre os diferentes países (BALCAEN; OOGHE, 2006; GARCÍA; MARQUÉS; SANCHÉZ, 2014; LIANG; TSAI; DAI; EBERLE, 2017; TIAN; YU, 2017). Assim, faz-se necessário acrescentar pesquisas de outros países, como Brasil, países da América Latina, Israel, que, nesta base de dados do BP, não tiveram nenhuma pesquisa de relevância.

Figura 7 – Time horizon (database) utilizado no conjunto da base de dados



Fonte: Resultados da pesquisa

Na avaliação do *time horizon* de utilização dos conjuntos de dados que compõe o BP (Figura 7), verifica-se que houve uma concentração de utilização do período de 1999 a 2007, as bases mais recentes utilizadas foram até o ano de 2015 e somente duas pesquisas chegaram até este período. A demanda para se atualizar os modelos, com conjuntos de dados maiores e mais atualizados, por um período de tempo maior poderia trazer implicações mais amplas em termos de resultados. Altman (2002) já demonstrava esta preocupação onde para o autor os principais fatores motivacionais técnicos incluem o refinamento das técnicas, inovações nas soluções analíticas, bases de dados maiores e melhoradas, para se traduzir a gestão do risco de crédito.

Algumas pesquisas não detalharam a descrição completa das variáveis utilizadas nos experimentos ou não forneceram o tamanho da base de dados utilizada, o que dificulta ainda mais a compreensão dos modelos e métodos desenvolvidos.

5. CONSIDERAÇÕES FINAIS

Esta pesquisa avaliou os estudos científicos mais relevantes sobre gestão do risco de crédito e *Artificial Intelligence*, analisou a sua evolução ao longo dos anos e também identificou possíveis lacunas na literatura, com o intuito de complementar o conhecimento e embasamento epistemológico com o diagnóstico coletivo e com as múltiplas visões apresentadas sobre o tema.

Para desenvolvimento deste trabalho empregou-se a metodologia ProKnow-C, que resultou, como suporte empírico, na seleção de 165 referências científicas mais relevantes. Nesta seleção não houve limitação temporal.

Diante da averiguação final, pode-se afirmar que a aplicação da tecnologia computacional no âmbito da gestão do risco de crédito, vem angariando atenção de forma singular, principalmente após a crise financeira ocorrida em meados de 2007/2008. Nota-se que

houve um aumento considerável de artigos publicados após esse período, o que pode ser explicado pela crise ocorrida, outra questão que também pode ser levantada é a melhoria na infraestrutura e evolução dos recursos computacionais, que são capazes de armazenar e transacionar uma vasta quantidade de dados, bem como o aperfeiçoamento dos métodos baseados em AI (MORO; CORTEZ; RITA, 2015).

Entretanto, apesar de todos os benefícios trazidos pela evolução dos modelos e técnicas baseados em AI e ANN, em relação a performance na precisão de predição, alguns autores discorrem sobre suas desvantagens e limitações. São citadas questões a serem aperfeiçoadas como a arquitetura utilizada onde, as decisões são baseadas em tentativas e erro, o que torna o processo demasiadamente lento em decorrência dos critérios e volume de dados. As ANN *feedforward* necessitam de reestruturação quando ocorrem ínfimas variações nos dados, outra questão a se discutir é a existência da grande dificuldade por parte dos usuários em interpretar a saída dos dados nos modelos de predição. Outra situação seria em relação as bases de dados, onde alguns autores alegam que os modelos não são capazes de tratar o desbalanceamento das bases de dados, podendo até comprometer sua performance. Estas limitações dificultam a aplicação desses modelos na *praxis*, tornando-os assim uma tecnologia “*black box*” (ZMIJEWSKI, 1984; WANG et al., 2011; OLSON et al., 2012; ZHANG; WANG; JI, 2013; CHUANG, 2013). Seria interessante avaliar o nível de dependência entre as variáveis, explicando o grau de influência de cada uma, dentro dos diversos modelos e técnicas, ou seja, implementar a perspectiva da análise fundamentalista aos modelos computacionais.

Os modelos apresentados por Altman (1968) e Ohlson (1980), LR e MDA, ainda são considerados relevantes pela capacidade preditiva, simplicidade e consistência, o que poucos modelos baseados em AI conseguiram apresentar (BARBOZA et al., 2017). Dentre os 103 métodos e técnicas apresentados no BP, estes dois métodos ainda estão entre os 7 mais aplicados nos estudos.

Em relação ao *time horizon* de utilização dos conjuntos de dados, verificou-se que houve uma concentração de utilização do período de 1999 a 2007, as bases mais recentes utilizadas foram até o ano de 2015 e somente duas pesquisas chegaram até este período. A demanda para se atualizar os modelos, com conjuntos de dados maiores, mais atualizados e por um período de tempo maior, poderia trazer implicações mais amplas em termos de resultados. Altman (2002) já demonstrava esta preocupação onde, para o autor, os principais fatores motivacionais técnicos incluem o refinamento das técnicas tradicionais, novas soluções analíticas, bases de dados maiores e melhoradas, para se traduzir a gestão do risco de crédito.

Observou-se que em relação a origem dos conjuntos de dados, ou seja, os países que foram utilizados para os experimentos, a maioria dos trabalhos empregaram conjuntos de dados da Alemanha, Austrália, US, Japão, Taiwan, China, Coreia e França. A utilização destas bases para se tratar a gestão do risco de crédito, permite que outros pesquisadores possam comparar novos modelos e seus resultados. Mas, quando esses dados são utilizados demasiadamente, podem não apresentar as condições específicas de outras regiões, mercados, ou segmentos, devido a questões regulatórias e as condições socio econômicas específicas, assim os experimentos podem levar a conclusões distorcidas e talvez não atenderem as demandas dos diversos mercados, pois os fatores que afetam a falência variam entre os diferentes países (BALCAEN; OOGHE, 2006; GARCÍA; MARQUÉS; SANCHÉZ, 2014; LIANG; TSAI; DAI; EBERLE, 2017; TIAN; YU, 2017). Assim, faz-se necessário acrescentar pesquisas de outros países, como Brasil, países da América Latina, Israel, que, nesta base de dados do BP, não tiveram nenhuma pesquisa de relevância.

Os artigos mais citados são o de Tam e Kiang (1992), que foram os precursores na implementação dos métodos baseados em AI e ANN para prever falência e o de Altman, Marco e Varetto (1994), que também utilizou métodos baseados em ANN, mas neste caso, Altman foi

o primeiro a aplicar a metodologia de análise discriminante para prever dificuldade financeira das firmas. Os dois artigos representam 11,9% do total de citações entre os 165 *papers* do BP.

A presente pesquisa não pretende generalizar os resultados em relação ao tema tratado, nem tão pouco entender de forma pormenorizada toda produção envolvida nos estudos. Assim, este trabalho apresentou através de uma revisão sistemática da literatura diversas análises através de indicadores, mapas e redes de *clusters*, demonstrando o acompanhamento da evolução de uma determinada área do conhecimento, sua arquitetura, características, distribuição e relevância. Algumas limitações foram identificadas como a restrição das bases de dados para consulta e a formulação de outras análises, questões e objetivos, como a análise de desempenho por método, permitindo assim a identificação de novas oportunidades para pesquisas futuras.

REFERÊNCIAS

- ABDOU, H. A., POINTON, J. Credit scoring, statistical techniques and evaluation criteria: a review of the literature. **Intelligent Systems in Accounting, Finance and Management**, 182-3, 59–88, 2011.
- ABELLÁN, J., CASTELLANO, J. G. A comparative study on base classifiers in ensemble methods for credit scoring. **Expert Systems with Applications**, 73, 1–10, 2017.
- ADNAN AZIZ, M., DAR, H. A. Predicting corporate bankruptcy: where we stand? **Corporate Governance: The International Journal of Business in Society**, 61, 18–33, 2006.
- ADDO, P. M., GUEGAN, D., HASSANI, B. Credit Risk Analysis Using Machine and Deep Learning Models. **SSRN Electronic Journal**, 2018.
- ALAKA, H. A., OYEDELE, L. O., OWOLABI, H. A., KUMAR, V., AJAYI, S. O., AKINADE, O. O., BILAL, M. Systematic review of bankruptcy prediction models: Towards a framework for tool selection. **Expert Systems with Applications**, 94, 164–184, 2018.
- ALLEN, L., SAUNDERS, A. A Survey of Cyclical Effects in Credit Risk Measurement Models. **SSRN Electronic Journal**, 2003.
- ALTMAN, E. I. Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy. **The Journal of Finance**, 234, 589, 1968.
- ALTMAN, E. I. Why businesses fail. **Journal of Business Strategy**, 34, 15-21, 1983.
- ALTMAN, E. I. Managing Credit Risk: A Challenge for the New Millennium. **Economic Notes**, 312, 201–214, 2002.
- ALTMAN, E. I., BAIDYA, T. K. N., DIAS, L. M. R. Assessing Potential Financial Problems for Firms in Brazil. **Journal of International Business Studies**, 102, 9-24, 1979.
- ALTMAN, E. I., MARCO, G., VARETTO, F. Corporate distress diagnosis: Comparisons using linear discriminant analysis and neural networks the Italian experience. **Journal of Banking Finance**, 183, 505–529, 1994.
- B3. **Brasil Bolsa e Balcão**. Disponível em: <<http://www.bmfbovespa.com.br>>. Acesso em: mar. 2019
- BANCO CENTRAL DO BRASIL – **BACEN**. Disponível em: <https://www.bcb.gov.br/fis/supervisao/basileia.asp>. Acesso em: mar. 2019
- BALCAEN, S., OOGHE, H. 35 years of studies on business failure: an overview of the classic statistical methodologies and their related problems. **The British Accounting Review**, 381, 63–93. 2006.
- BARBOZA, F., KIMURA, H., ALTMAN, E. Machine learning models and bankruptcy prediction. **Expert Systems with Applications**, 83, 405–417, 2017.
- BEAVER, W. H. Financial ratios as predictors of failure. **Journal of Accounting Research**, v. 4, Empirical Research in Accounting: Selected, pp. 71-111, 1966.

- BROCKETT, P. L., COOPER, W. W., Golden, L. L., Pitaktong, U. A Neural Network Method for Obtaining an Early Warning of Insurer Insolvency. **The Journal of Risk and Insurance**, 613, 402, 1994.
- COLE, F. J; EALES, N. B. The history of comparative anatomy. Part I—A statistical analysis of the literature. **Science Progress** 1144, April 1917, p. 578–96, 1917.
- DE ANDRES, J., LANDAJO, M., LORCA, P. Forecasting business profitability by using classification techniques: A comparative analysis based on a Spanish case. **European Journal of Operational Research**, 1672, 518–542, 2005.
- DE AZEVEDO, R. C., ENSSLIN, L., JUNGLES, A. E. A review of risk management in construction: opportunities for improvement. **Modern Economy**, 504, 367, 2014.
- DU JARDIN, P. Dynamics of firm financial evolution and bankruptcy prediction. **Expert Systems with Applications**, 75, 25–43, 2017.
- DU JARDIN, P. Failure pattern-based ensembles applied to bankruptcy forecasting. **Decision Support Systems**, 107, 64–77, 2018.
- ENSSLIN, L., ENSSLIN, S. R., DUTRA, A., NUNES, N. A., REIS, C. BPM governance: a literature analysis of performance evaluation. **Business Process Management Journal**, 231, 71–86, 2017.
- GARCÍA, V., MARQUÉS, A. I., SÁNCHEZ, J. S. An insight into the experimental design for credit risk and corporate bankruptcy prediction systems. **Journal of Intelligent Information Systems**, 441, 159–189, 2014.
- GARCÍA, V., MARQUÉS, A. I., SÁNCHEZ, J. S. Exploring the synergetic effects of sample types on the performance of ensembles for credit risk and corporate bankruptcy prediction. **Information Fusion**, 47, 88–101, 2019.
- GENG, R., BOSE, I., CHEN, X. Prediction of financial distress: An empirical study of listed Chinese companies using data mining. **European Journal of Operational Research**, 2411, 236–247, 2015.
- GLANZEL, W. Coauthorship patterns and trends in the sciences 1980-1998: A bibliometric study with implications for database indexing and search strategies, 2002.
- GRIFFIN, J. M., LEMMON, M. L. Book-to-market equity, distress risk, and stock returns. **The Journal of Finance**, 575, 2317-2336, 2002.
- GUO, Y., ZHOU, W., LUO, C., LIU, C., XIONG, H. Instance-based credit risk assessment for investment decisions in P2P lending. **European Journal of Operational Research**, 2492, 417-426, 2016.
- HILLEGEIST, S. A. et al. Assessing the probability of bankruptcy. **Review of accounting studies**, v. 9, n. 1, p. 5-34, 2004.
- HAJEK, P., OLEJ, V., MYSKOVA, R. Forecasting Corporate Financial Performance using sentiment in annual reports for stakeholders' decision-making. **Technological and Economic Development of Economy**, 204, 721–738, 2014.
- HU, Y.-C. Bankruptcy prediction using ELECTRE-based single-layer perceptron. **Neurocomputing**, 7213-15, 3150–3157, 2009.
- HUANG, Z., CHEN, H., HSU, C.-J., CHEN, W.-H., WU, S. Credit rating analysis with support vector machines and neural networks: a market comparative study. **Decision Support Systems**, 374, 543–558, 2004.
- HUANG, J.-J., TZENG, G.-H., ONG, C.-S. Two-stage genetic programming 2SGP for the credit scoring model. **Applied Mathematics and Computation**, 1742, 1039–1053, 2006.
- JOURNAL CITATION REPORTS. **InCites Journal Citation Reports**. Disponível em <https://jcr.incites.thomsonreuters.com>. Acesso em jun. 2019.

- KARAN, M. B., ULUCAN, A., KAYA, M. Credit risk estimation using payment history data: a comparative study of Turkish retail stores. **Central European Journal of Operations Research**, 212, 479–494, 2012.
- KRUPPA, J., SCHWARZ, A., ARMINGER, G., ZIEGLER, A. 2013. Consumer credit risk: Individual probability estimates using machine learning. **Expert Systems with Applications**, 4013, 5125–5131, 2013.
- LAHSASNA, A., AINON, R. N., TEH, Y. W. Credit Scoring Models Using Soft Computing Methods: A Survey. **Int. Arab J. Inf. Technol.**, 72, 115-123, 2010.
- LESSMANN, S., BAESENS, B., SEOW, H.-V., THOMAS, L. C. Benchmarking state-of-the-art classification algorithms for credit scoring: An update of research. **European Journal of Operational Research**, 2471, 124–136, 2015.
- LI, H., SUN, J. Hybridizing principles of the Electre method with case-based reasoning for data mining: Electre-CBR-I and Electre-CBR-II. **European Journal of Operational Research**, 1971, 214–224, 2009.
- LIANG, D., TSAI, C.-F., DAI, A.-J., EBERLE, W. A novel classifier ensemble approach for financial distress prediction. **Knowledge and Information Systems**, 542, 437–462, 2017.
- MARQUÉS, A. I., GARCÍA, V., SÁNCHEZ, J. S. Exploring the behaviour of base classifiers in credit scoring ensembles. **Expert Systems with Applications**, 3911, 10244–10250, 2012.
- MARQUÉS, A. I., GARCÍA, V., SÁNCHEZ, J. S. On the suitability of resampling techniques for the class imbalance problem in credit scoring. **Journal of the Operational Research Society**, 647, 1060–1070, 2013.
- Martin, D. Early warning of bank failure. **Journal of Banking Finance**, 13, 249–276, 1977.
- MIN, J., LEE, Y. Bankruptcy prediction using support vector machine with optimal choice of kernel function parameters. **Expert Systems with Applications**, 284, 603–614, 2005.
- MORO, S., CORTEZ, P., RITA, P. Business intelligence in banking: A literature analysis from 2002 to 2013 using text mining and latent Dirichlet allocation. **Expert Systems with Applications**, 423, 1314–1324, 2015.
- ODOM, M. D., SHARDA, R. A neural network model for bankruptcy prediction. **IJCNN International Joint Conference on Neural Networks**. pp. 163–168. San Diego, CA, 1990.
- OHLSON, J. A. Financial Ratios and the Probabilistic Prediction of Bankruptcy. **Journal of Accounting Research**, 181, 109, 1980.
- PAL, R., KUPKA, K., ANEJA, A. P., MILITKY, J. Business health characterization: A hybrid regression and support vector machine analysis. **Expert Systems with Applications**, 49, 48–59, 2016.
- OLSON, D. L., DELEN, D., MENG, Y. Comparative analysis of data mining methods for bankruptcy prediction. **Decision Support Systems**, 522, 464–473, 2012.
- PAN, W.-T. A new Fruit Fly Optimization Algorithm: Taking the financial distress model as an example. **Knowledge-Based Systems**, 26, 69–74, 2012.
- PRICE, D. J. Citation measures of hard science, soft science, technology, and nonscience. Communication among scientists and engineers, 3-22, 1970.
- PRITCHARD, A. Statistical bibliography or bibliometrics. **Journal of documentation**, 254, 348-349, 1969.
- RIBEIRO, B., CHEN, N., KOVACEC, A. Shaping graph pattern mining for financial risk. **Neurocomputing**, 2017.
- SERASA EXPERIAN. **Indicadores econômicos**. Disponível em: <https://www.serasaexperian.com.br>. Acesso em: abr. 2019.

- SHIN, K.-S., LEE, T. S., KIM, H. An application of support vector machines in bankruptcy prediction model. **Expert Systems with Applications**, 281, 127–135, 2005.
- SCIMAGO. **Scimago Journal Country Rank**. SJR. Disponível em: <https://www.scimagojr.com/>. Acesso em: jun. 2019.
- SUN, J., FUJITA, H., CHEN, P., LI, H. Dynamic financial distress prediction with concept drift based on time weighting combined with Adaboost support vector machine ensemble. **Knowledge-Based Systems**, 120, 4–14, 2017.
- SUN, J., LANG, J., FUJITA, H., LI, H. Imbalanced enterprise credit evaluation with DTE-SBD: Decision tree ensemble based on SMOTE and bagging with differentiated sampling rates. **Information Sciences**, 425, 76–91, 2018.
- SUN, J., LI, H., HUANG, Q.-H., HE, K.-Y. Predicting financial distress and corporate failure: A review from the state-of-the-art definitions, modeling, sampling, and featuring approaches. **Knowledge-Based Systems**, 57, 41–56, 2014.
- TAFFLER, R. J. Forecasting Company Failure in the UK Using Discriminant Analysis and Financial Ratio Data. **Journal of the Royal Statistical Society**. Series A General, 1453, 342, 1982.
- TAM, K. Y., KIANG, M. Predicting Bank Failures: A Neural Network Approach. **Applied Artificial Intelligence**, 44, 265–282, 1990.
- TAM, K. Y., KIANG, M. Y. Managerial Applications of Neural Networks: The Case of Bank Failure Predictions. **Management Science**, 387, 926–947, 1992.
- TIAN, S., YU, Y. Financial ratios and bankruptcy predictions: An international evidence. **International Review of Economics Finance**, 51, 510–526, 2017.
- WANG, G., CHEN, G., CHU, Y. A new random subspace method incorporating sentiment and textual information for financial distress prediction. **Electronic Commerce Research and Applications**, 29, 30–49, 2018.
- WANG, G., HAO, J., MA, J., JIANG, H. A comparative assessment of ensemble learning for credit scoring. **Expert Systems with Applications**, 381, 223–230, 2011.
- WANG, G., MA, J. A hybrid ensemble approach for enterprise credit risk assessment based on Support Vector Machine. **Expert Systems with Applications**, 395, 5325–5331, 2012.
- WANG, J., VEUGELERS, R., STEPHAN, P. Bias against Novelty in Science: A Cautionary Tale for Users of Bibliometric Indicators, 2016.
- ZELENKOV, Y., FEDOROVA, E., CHEKRIZOV, D. Two-step classification method based on genetic algorithm for bankruptcy forecasting. **Expert Systems with Applications**, 88, 393–401, 2017.
- ZHANG, Y., WANG, S., JI, G. A Rule-Based Model for Bankruptcy Prediction Based on an Improved Genetic Ant Colony Algorithm. **Mathematical Problems in Engineering**, 2013, 1–10, 2013.
- ZHAO, D., HUANG, C., WEI, Y., YU, F., WANG, M., CHEN, H. An Effective Computational Model for Bankruptcy Prediction Using Kernel Extreme Learning Machine Approach. **Computational Economics**, 492, 325–341, 2016.
- ZHOU, L. Performance of corporate bankruptcy prediction models on imbalanced dataset: The effect of sampling methods. **Knowledge-Based Systems**, 41, 16–25, 2013.
- ZHU, Y., XIE, C., WANG, G.-J., YAN, X.-G. Comparison of individual, ensemble and integrated ensemble machine learning methods to predict China's SME credit risk in supply chain finance. **Neural Computing and Applications**, 28S1, 41–50, 2016.
- ZMIJEWSKI, M. E. Methodological Issues Related to the Estimation of Financial Distress Prediction Models. **Journal of Accounting Research**, 22, 59, 1984.