

Repositório ISCTE-IUL

Deposited in *Repositório ISCTE-IUL*:

2023-10-11

Deposited version:

Accepted Version

Peer-review status of attached file:

Peer-reviewed

Citation for published item:

Ildefonso, M. V. S., Laureano, R. M. S. & Vasarhelyi, M. A. (2023). Modelos preditivos de insolvências: Uma revisão sistemática da literatura. In 2023 18th Iberian Conference on Information Systems and Technologies (CISTI). (pp. 1-6). Aveiro, Portugal: IEEE.

Further information on publisher's website:

10.23919/CISTI58278.2023.10211516

Publisher's copyright statement:

This is the peer reviewed version of the following article: Ildefonso, M. V. S., Laureano, R. M. S. & Vasarhelyi, M. A. (2023). Modelos preditivos de insolvências: Uma revisão sistemática da literatura. In 2023 18th Iberian Conference on Information Systems and Technologies (CISTI). (pp. 1-6). Aveiro, Portugal: IEEE., which has been published in final form at <https://dx.doi.org/10.23919/CISTI58278.2023.10211516>. This article may be used for non-commercial purposes in accordance with the Publisher's Terms and Conditions for self-archiving.

Use policy

Creative Commons CC BY 4.0

The full-text may be used and/or reproduced, and given to third parties in any format or medium, without prior permission or charge, for personal research or study, educational, or not-for-profit purposes provided that:

- a full bibliographic reference is made to the original source
- a link is made to the metadata record in the Repository
- the full-text is not changed in any way

The full-text must not be sold in any format or medium without the formal permission of the copyright holders.

Modelos preditivos de insolvências: uma revisão sistemática da literatura

Predictive models of insolvency: a systematic literature review

Mariana V. S. Ildefonso

Instituto Universitário de Lisboa
ISCTE-IUL

Av. das Forças Armadas, Lisboa
1649-026 Lisboa, Portugal

Mariana.Viegas.Silva.Ildefonso@iscte-iul.pt

Raul M. S. Laureano

Instituto Universitário de Lisboa
ISCTE-IUL, BRU, ISTAR

Av. das Forças Armadas, Lisboa
1649-026 Lisboa, Portugal

raul.laureano@iscte-iul.pt

Miklos A. Vasarhelyi

Rutgers Business School

1 Washington Pl

Newark NJ 07102, USA

miklosv@business.rutgers.edu

Resumo — Este estudo visa explorar a importância da previsão de dificuldades financeiras, insolvências e falências para investidores, credores, bancos e outros *stakeholders* das empresas, devido à probabilidade de incumprimento das mesmas. Desde a crise financeira de 2008, tem sido uma prioridade para as empresas encontrarem o melhor modelo preditivo para a previsão de eventuais condições débeis. Este estudo apresenta uma revisão sistemática do trabalho já realizado e aumenta o grau de conhecimento através da utilização de técnicas avançadas de análise de dados e utilizando indicadores financeiros e não financeiros.

Palavras Chave – Insolvência, Modelos Preditivos, Machine Learning, Data Mining.

Abstract — *This study aims to explore the importance of predicting financial distress, insolvency and bankruptcy for investors, creditors, banks and other stakeholders of companies due to the likelihood of corporate default. Since the 2008 financial crisis, it has been a priority for firms to find the best predictive model for forecasting possible weak conditions. This study presents a systematic review of work already done and increases the degree of knowledge through the use of advanced data analysis techniques and using financial and non-financial indicators.*

Keywords – *Insolvency, Predictive Models, Machine Learning, Data Mining.*

I. INTRODUÇÃO

A previsão da entrada em processos de insolvência de uma empresa é importante na medida em que prepara os gestores para o que se avizinha. Para os próprios investidores é uma forma de perceberem se investir numa certa empresa será bom ou não tendo em conta a sua saúde financeira. A previsão da falência é crucial para a prevenção ou mitigação de ciclos económicos negativos na economia, ajudando a identificar futuras falhas no negócio e a fornecer atempadamente chamadas de atenção para dificuldades financeiras, tal como a previsão de entrada em processos de insolvência [1].

Apesar de existirem nos dias de hoje já bastantes modelos preditivos de dificuldades financeiras, falências e insolvências, ainda há muito a descobrir e limitações a serem colmatadas com mais pistas futuras de forma a criar modelos mais inclusivos,

com uma maior importância para indicadores não financeiros e tendo em conta o impacto ambiental, e com maior precisão que os anteriores.

Este estudo procura sistematizar o conhecimento científico sobre a entrada em processos de insolvência de diferentes empresas, mais concretamente a sua previsão a partir de técnicas, ditas, de *machine learning* e de *data mining*. Em particular, esta revisão sistemática da literatura (RSL) propõe-se a responder à pergunta: de que modo tem sido efetuada a previsão de entrada em insolvência/falência de uma empresa ou o aparecimento de dificuldades financeiras na mesma? Mais especificamente, visa responder às três questões seguintes: (1) Quais os âmbitos e contextos em que foram realizados os estudos?; (2) Quais os modelos utilizados na previsão das insolvências/falências/ dificuldades financeiras e sua validação?; e (3) Como são avaliados os resultados dos estudos?.

Como resposta à questão de investigação, este estudo contribui, para além da sistematização do conhecimento, com a identificação de pistas de investigação que possam melhorar a qualidade das previsões, como sejam, a inclusão de indicadores não financeiros nos modelos (e.g., género da direção da empresa e a opinião do auditor).

II. CONCEITOS

Uma empresa encontra-se em dificuldades financeiras quando não é capaz de cumprir as suas obrigações financeiras para com os credores, o que, em contrapartida, leva a uma reestruturação ou falência da empresa [2].

De acordo com o artigo 1º do Código da Insolvência e da Recuperação de Empresas (CIRE) “o processo de insolvência é um processo de execução universal que tem como finalidade a satisfação dos credores pela forma prevista num plano de insolvência, baseado, nomeadamente, na recuperação da empresa compreendida na massa insolvente, ou, quando tal não se afigure possível, na liquidação do património do devedor insolvente e a repartição do produto obtido pelos credores”.

Uma empresa pode encontrar-se no processo judicial de falência quando se depara com uma situação de insolvência, onde está incapaz de cumprir algumas das suas obrigações por

falta de meios financeiros, ou, então, a empresa pode estar num período de crise e deparar-se com dificuldades financeiras que a impedem de cumprir as suas obrigações.

Enquanto a previsão de falências se concentra principalmente na previsão do fim do ciclo de vida de uma empresa, com relativamente poucas hipóteses de sobrevivência através de reestruturação, a previsão de dificuldades financeiras é uma ocorrência mais comum, quando um negócio tem dificuldades temporárias no cumprimento das suas obrigações. A previsão das dificuldades financeiras desempenha um papel cada vez mais importante na sociedade de hoje, uma vez que tem um impacto significativo nas decisões de empréstimo e na rentabilidade das instituições financeiras. Desde a crise financeira ocorrida em 2008, houve um aumento no foco das instituições financeiras no risco de crédito e na previsão de dificuldades financeiras nas empresas [3].

A criação de modelos preditivos para o efeito tem sido um desafio. Há alguns sinais no reporte financeiro das empresas a serem tomados em atenção, tal como a redução dos lucros e os pagamentos de obrigações [3]. Por outro lado, técnicas analíticas mais avançadas têm sido aplicadas. Destas, as técnicas de *machine learning*, que são métodos ou algoritmos criados para aprenderem os padrões dos dados recolhidos e conseguirem obter previsões com base nesses padrões para novos dados [4], e as técnicas de *data mining*, que são técnicas que utilizam algoritmos matemáticos para encontrar informação oculta numa enorme quantidade de dados e analisarem os padrões indexados a estes dados [5].

III. METODOLOGIA

Uma RSL é “uma revisão onde são formuladas perguntas e em que são utilizados procedimentos sistemáticos e explícitos para selecionar e fazer uma avaliação crítica da investigação relevante, a fim de recolher e avaliar os dados dos estudos incluídos na revisão” [6]. Esta envolve três passos principais, definidos como a determinação da questão de investigação, elaboração da estratégia de pesquisa e seleção e, por fim, a realização da extração e síntese dos artigos selecionados para responderem a esta questão [7]. A Figura I sintetiza as etapas da seleção e análise dos artigos que permitem responder à questão de investigação formulada.


Os artigos são selecionados a partir de uma procura automática numa base de dados com diferentes publicações científicas, com base na aplicação de uma *query* ao título, palavras-chave e resumo do artigo e ainda tendo em conta critérios de inclusão/exclusão. Seleciona-se a plataforma *Web of Science* (WoS) (<https://www.webofscience.com/>) devido à sua relevância em áreas de investigação, como a gestão e a economia, tendo bastantes *journals* indexados, e pelo facto de ser uma plataforma mais seletiva [8].

As palavras-chave utilizadas na *query* resultam da identificação na literatura de termos identificativos de insolvência, falência e dificuldades financeiras, de previsão e de métodos de análise de dados, tendo sido validados por especialistas (e.g., professores de contabilidade e finanças). Assim, a *query* aplicada é “(*predict** OR *detect**) AND (*bankrupt** OR “*financial distress*” OR *insolven**) AND (“*machine learning*” OR “*data mining*”)”.

A partir daqui resultaram 42 artigos, que posteriormente foram submetidos a critérios de inclusão e exclusão. Os critérios de inclusão baseiam-se em os estudos abordarem a insolvência e falência em termos de previsão, analisarem indicadores financeiros de empresas e conterem uma componente empírica. Já os critérios de exclusão tratam-se de não conter *Proceeding papers*, *Early Access*, *Review Articles* e artigos que não tenham fator de impacto de acordo com o WoS.

Tendo em conta os critérios de inclusão e exclusão, bem como da leitura do resumo de cada artigo, excluíram-se 21 artigos. Assim, são analisados 21 artigos ([9][10][11][12][13][14][15][16][17][18][3][19][20][21][22][23][24][25][26][27][28]), sendo o mais antigo de 2000 e os mais recentes de 2022.

FIGURA I - PROCESSO DE SELEÇÃO DOS ARTIGOS PARA ANÁLISE



Após a leitura e revisão dos artigos selecionados, é feita uma avaliação da sua qualidade tendo em conta a sua contribuição para a resposta às três questões colocadas. Esta avaliação tem por base 13 itens, colocados na forma de questão, sendo que a cada é atribuída uma cotação de 0 se não responde à questão; 0,5 se responde parcialmente e 1, se responde totalmente.

As questões dividem-se em: 1.1) Define claramente insolvência/falência/dificuldade financeira?; 1.2) É evidenciada a diferença entre insolvências, falências e dificuldades financeiras?; 1.3) Justifica a finalidade e o contexto do estudo?; 1.4) A amostra é caracterizada adequadamente?; 1.5) Apresenta a metodologia adequadamente?; 2.1) Apresenta, justificando adequadamente, as variáveis utilizadas?; 2.2) Apresenta, descreve e justifica a(s) técnica(s)/ algoritmo(s) utilizada(o(s)?; 2.3) Compara diferentes modelos preditivos?; 2.4) Avalia convenientemente o(s) modelo(s)?; 2.5) São realizadas técnicas de robustez e de sensibilidade?; 3.1) Os resultados do estudo são devidamente discutidos?; 3.2) São identificados claramente os contributos (teóricos e práticos) e os impactos do estudo?; 3.3) São identificadas claramente as limitações do estudo?.

IV. ANÁLISE SISTEMÁTICA DOS ARTIGOS

Os 21 artigos selecionados para análise são analisados em três diferentes vertentes. Primeiro, caracterizam-se os âmbitos e objetivos dos estudos, referindo-se ainda o tipo de empresa

estudada. Depois, analisam-se os modelos utilizados nas diferentes previsões tendo em conta o objetivo do estudo, caracterizando-se também a sua forma de validação. Finalmente, passa-se a uma parte de avaliação, também, esta dividida em duas fases. Numa primeira fase, avaliam-se os resultados dos estudos e, em seguida, avalia-se a qualidade dos artigos selecionados e analisados.

A. Contexto dos estudos

Os artigos selecionados descrevem estudos muito diversificados, quer quanto ao seu âmbito e objetivo, quer quanto aos tipos de empresas estudados (Tabela I).

TABELA I. CONTEXTO DOS ESTUDOS

Ref	Objetivo do estudo	Anos (País)	Nº entidades (balanceado)
9	Perceber se as previsões de falência podem ser melhoradas utilizando os algoritmos <i>RNN</i> e <i>LSTM</i>	2007-2019 (NE)	454 752 (Não)
10	Comparar o desempenho dos modelos estáticos, dinâmicos e de <i>ML</i> na previsão de DF nas cotadas	1992-2018 (China)	29 000 (2 métodos)
11	Dar ênfase à importância de variáveis industriais/regionais na previsão de falências	2007-2015 (Itália)	70 309 (Não)
12	Enriquecer a literatura sobre <i>EWM</i> , preenchendo esta lacuna através da utilização de metodologias de <i>ML</i> de previsão de falências	2009-2016 (Itália)	7 795 (Não)
13	Mostrar que a importância das características pode ser medida pelos próprios modelos de previsão de falências	2009-2015 (Coreia do Sul)	546 619 (Não)
14	Propor um modelo para prever DF em PME que inclua fatores temporais e que preveja os <i>ratings</i> dos créditos das PME num horizonte temporal de 1 ano aplicando três técnicas de <i>ML</i>	NE (Estónia, Letónia e Lituânia)	12 000 (Não)
15	Comparar os modelos de previsão de insolvências em PME e encontrar o que tenha maior <i>accuracy</i>	2010-2014 (NE)	4 358 (Não)
16	Explorar os fatores integrados e os múltiplos modelos que podem melhorar o desempenho dos modelos para a previsão de DF em empresas chinesas cotadas	2013-2018 (China)	424 (Sim)
17	Comparar diferentes algoritmos na previsão de insolvências bancárias	2008-2014 (EUA)	11 573 (Não)
18	Prever falências utilizando técnicas de <i>mimetic intelligent emulating</i>	NE	250 (Não)
3	Comparar a performance de modelos de <i>ML</i> na previsão de DF em empresas cotadas	2010-2016 (Tailândia)	64 (Sim)
19	Melhoria na precisão da previsão de falências , comparando modelos e usando técnicas de <i>ML</i>	1985-2013 (EUA, Canadá)	13 300 (Não)
20	Investigar o desempenho de diferentes modelos de previsão de DF em empresas chinesas com abordagens de <i>feature selection</i> baseadas em conhecimentos de <i>data mining</i> ou <i>domain knowledge</i>	2001-2011 (China)	10 365 (Não)
21	Aplicar <i>data mining</i> para prever quais as empresas cotadas suscetíveis de receber o rótulo ST	2001-2008 (China)	214 (Sim)
22	Comparar modelos de previsão de falências com base na <i>accuracy</i> e o nº de regras	NE (NE)	NE
23	Conseguir modelos para classificar empresas iranianas cotadas falidas e não falidas utilizando <i>GEP</i> e <i>MEP</i>	1999-2006 (Irão)	136 (Não)
24	Criar modelo preditivo das DF com diversas técnicas (tradicionais e de <i>ML</i>), utilizando rácios financeiros e não financeiros	1999-2006 (Tailândia)	68 (Sim)
25	Criar um modelo a partir de um algoritmo para a previsão de DF das empresas cotadas	2000-2005 (China)	198 (Não)
26	Propor uma abordagem de <i>MCLP</i> para a prospeção de dados para a previsão de falências , prevendo resultados futuros com base em dados passados	1992-1998 (EUA)	NE
27	Encontrar o modelo de previsão do início da falência de uma empresa com o menor erro ao quadrado	1996-1997 (EUA)	244 094 (Não)
28	Estudar rácios financeiros como preditores da falência de empresas japonesas	NE (Japão)	986 (Não)

Notas: DF-Dificuldades Financeiras; EWM-Early Warning Models; GEP-Gene Expression Programming; LSTM-Long short-term Memory; MCLP-Multiple Criteria Linear Programming; MEP-Multi-expression Programming; ML-Machine learning; NE-Não Especificado; PM-Pequeñas e Médias; PME-Pequeñas e Médias Empresas; RNN-Recurrent Neural Networks; ST-Special Treatment.

Relativamente ao âmbito verifica-se que mais de metade dos artigos selecionados (n=11) abordam o tema das falências,

sendo que as insolvências são o foco de apenas dois estudos [15][17]. Destaca-se, ainda, que a previsão de dificuldades financeiras surge em oito estudos, o que revela alguma preocupação dos investigadores em preverem com bastante antecedência possíveis falências, já que as dificuldades financeiras são os primeiros sinais de que a sustentabilidade financeira das empresas possa estar comprometida (e.g., [16]).

Naturalmente, todos os estudos incidem sobre modelos de previsão. No entanto, alguns estudos não têm como principal objetivo criar modelos preditivos das falências, insolvências ou dificuldades financeiras, mas sim aplicar novos algoritmos para problemas de previsão (e.g., algoritmos de *machine learning*) para ver de que forma estes permitem melhorar a qualidade das previsões (e.g., [19][9]). Outros estudos pretendem criar de raiz o melhor modelo preditivo de falências, insolvências ou dificuldades financeiras (e.g., [23][25]).

Já no que respeita aos períodos (temporais) da análise constata-se igualmente muita diversidade, variando estes entre três meses [3] e 29 anos [19]. Assim, muitos estudos consideram nos seus modelos possíveis impactos de crises económicas, como a de 2008 (e.g., [19][17]).

Quanto ao tipo de empresas estudados, verifica-se que mais de metade dos artigos selecionados (n=11) aplicam estudos em empresas cotadas pela importância que têm para os investidores (e.g., [25] e geograficamente estes estudos têm maior impacto na China, com cinco dos 21 artigos selecionados (e.g., [21][20]).

Já no que se refere à dimensão da empresa, verifica-se que apenas quatro artigos aplicam o seu estudo a PME (Pequenas e Médias Empresas) (e.g., [11][13]) e que três dos 21 artigos aplicaram os estudos ao setor bancário/crédito ([27][14][17]). No entanto, grande parte dos estudos não identifica o setor em estudo (e.g., [26][28]) ou estudam diversos sectores (e.g., [11][15][3]).

Por último, fazendo uma análise quantitativa dos dados, constata-se que mais de metade dos artigos (66,7%), utiliza dados que não estão equilibrados, isto é, em que o número de empresas “saudáveis” é diferente do número de empresas que se encontram em dificuldades financeiras, insolvência ou falência, o que poderá causar dificuldades na avaliação dos modelos (e.g., [11][9]). Por fim, a base de dados mais utilizada para a recolha de dados foi a China Stock Market and Accounting Research (CSMAR), utilizada em todos os cinco artigos em que foram recolhidos dados da China (e.g., [25]).

B. Modelos utilizados na previsão e sua validação

Os artigos selecionados descrevem os diferentes algoritmos utilizados e as variáveis utilizadas. Adicionalmente, apresentam os métodos de validação, as métricas de qualidade e, por fim, os algoritmos que apresentam melhor performance e as variáveis predictoras mais importantes (Tabela II).

Relativamente aos algoritmos utilizados para classificação, isto é, em que a variável dependente é binária (1, se está em falência/insolvência/dificuldades financeiras, 0, caso contrário), verifica-se uma grande variedade e que, com exceção de um artigo que utilizou programação linear multicritério [23], são utilizados e comparados diversos algoritmos. Destaca-se que nove estudos utilizam árvores de decisão comparando diferentes algoritmos (e.g., [27][28]) e que as redes neurais são

igualmente populares, quer na sua tipologia mais simples (e.g., [11][14][22]), quer em mais complexas (e.g., [9][16][18]).

TABELA II. CARACTERÍSTICAS DOS MODELOS CRIADOS PELOS ESTUDOS

Ref	Algoritmo (melhor a negrito)	Nº var. ind.- tipo var. ind.	Métricas do melhor modelo
9	<i>Simple RNN technique; a modified RNN structure known as the LSTM; LR; RF; SVM; Ensemble model</i>	8-IF	A (0,7236-0,9936); P (0,0001-0,0058); R (0,2174-0,4783)
10	<i>Logit; Static GLM; GAM; Dynamic Hazard; DT; RF</i>	16-Rácios contabilísticos, de mercado e de crescimento	A (9,75%-94,72%); S (100%); Sp (9,72%-94,72%);
11	<i>LR; ANN; RF; XGBoost</i>	24-IF e variáveis industriais/regionais	TPR (84,63%-89,73%)
12	<i>LASSO; RF; ANN; Gradient Boosted Machine</i>	26-IF e demográficos	AUC (0,500-0,983)
13	<i>XGBoost; LightGBM</i>	25-IF	AUC (0,876-0,919)
14	<i>LR; ANN; RF</i>	23-IF	A (52,01%-52,89%); S (60,69%-65,83%); Sp (51,11%-51,58%);
15	<i>LR; DT; ANN, boosted DT e ensemble model</i>	37-Capacidade de gestão, viabilidade do negócio e capacidade técnica	A (<3 anos: 59,3%-69,1%; >3 anos: 62,8%-82,7%)
16	<i>LR; SVM; DT; RF; GBDT; Xgboost; bagging SVM; voting; stacking; DNN; RNN; LSTM</i>	74-IF; indicadores de gestão e textuais	A (73,81%-85,70%)
17	<i>LR; LDA; RF; SVM; ANN; CRF</i>	23-CAMELS	Balanced A (0,774-0,992)
18	<i>BPNN; PNN; RBFNN; GRNN</i>	6-Industrial, management e operating risks, financial flexibility, credibility, competitiveness	A (84,81%-99,96%); S (51,78%-100%); Sp (58,94%-100%)
3	<i>SVM; HACT; Hybrid GA-fuzzy clustering e XGBoost; unsupervised classifier DBN; the hybrid DBN-SVM model</i>	16-IF	A (70,3%-90,6%); S (85,9%-93,7%)
19	<i>SVM; boosting; bagging; RF (CART); ANN; LR; DA</i>	11-IF	A (52,18%-87,06%); S (52,05%-86,71%)
20	<i>LR; KNN; DT (C4.5); Ripper; ANN; SVM</i>	169-IF e variáveis de mercado	A (0,7964-0,9397); S (0,7062-0,9860); Sp (0,6738-0,9822)
21	<i>ANN; DT; SVM</i>	31-IF	A (0,711-0,788); S (0,728-0,799); P (0,636-0,732)
22	<i>ANN (MLP, RBF); DT (ID3, C4.5, C5 e CART); LR; SVM</i>	19-IF, data year e CIK number	A (0,609-0,948)
23	<i>GEP e MEP; LR; LSR</i>	4-IF	A (79,41%-91,18%); S (80%-95%); Sp (78,57%-85,71%)
24	<i>ANN; Clusters (K-means)</i>	13-IF e não financeiros	A (60%-82,14%)
25	<i>AOI; IG; DT</i>	35-IF	A (81,25%-95,33%)
26	<i>MCLP</i>	5-IF	S (71%-100%); Sp (81%-100%)
27	<i>DT (C4.5 and C5.0); LSR</i>	255-NE	NE
28	<i>DT (C 4.5, SIBILE, CART); LR; Stepdisc</i>	66-IF e tipo de indústria	A (85%-87%)

Notas: ANN- Artificial Neural Networks; AOI- Attribute-Oriented Induction; BPNN- Back Propagation Neural Network; CAMELS- Capital, Asset Quality, Management, Earnings, Liquidity, and Sensitivity; CART- Classification and Regression Trees; CRF- Random Forests of Conditional Inference Trees; DA- Discriminant Analysis; DBN- Deep Belief Network; DNN-Deep Neural Network; DT- Decision Tree; GA- Genetic Algorithm; GAM- Generalized Additive Model; GBDT- Gradient Boosting Decision Tree; GEP- Gene Expression Programming; GLM- Generalized Linear Model; GRNN- Generalized Regression Neural Network; HACT- Hybrid Associative Classifier with Translation; IF- Indicadores Financeiros; IG- Information Gain; KNN- K-Nearest Neighbors; LASSO- Least Absolute Shrinkage and Selection Operator; LDA- Linear Discriminant Analysis; LR- Logistic Regression; LSR- Least squares regression; LSTM- Long short-term memory; MCLP- Multiple criteria linear programming; MEP- Multi-expression Programming; MLP- multi-layer Perceptron; NE- Não Especificado; PNN-Probabilistic Neural Network; RBF- Radial Basis Function; RBFNN-Radial Basis Neural Network; RF- Random Forest; RNN- Recurrent Neural Network; ST- Special Treatment; SVM- Support Vector Machine; A- Accuracy; P-Precision; S-Sensitivity; Sp-Specificity; TPR-True Positive Rate.

Em termos das diferentes variáveis independentes, as mais usadas (em 76,2% dos artigos) foram os indicadores financeiros, (e.g., [23][25]). Naturalmente, cada estudo teve em conta um número de variáveis diferente, variando entre quatro [23] e 255

[27]. A seleção destas, em 16 dos 21 artigos, é feita maioritariamente a partir da literatura (e.g., [19][20]).

Quanto ao balanceamento dos dados, 66,7% dos estudos não utiliza dados balanceados e, como tal, em parte deles, foram usadas técnicas para estabelecer um equilíbrio nas amostras de cada tipo de empresa (e.g., insolventes e ativas saudáveis). Dois artigos aplicam a técnica de *synthetic minority over-sampling technique (SMOTE)* que aumenta a amostra da classe minoritária [9][15]; outro aplica *class weighted loss function* que trata de atribuir um peso maior à classe minoritária [11]; e um aplica três estratégias distintas: replicar aleatoriamente as instâncias na classe minoritária; gerar amostras artificialmente equilibradas de acordo com o *bootstrapping*; impor um custo mais elevado quando são cometidos erros na classe minoritária [12].

Na ótica da avaliação dos modelos, a maior parte dos estudos recorre à validação cruzada (e.g., [18][20]) e tendem a utilizar diferentes métricas de avaliação, sendo a mais comum a *accuracy*, utilizada em 16. Esta métrica tem os seus valores a variar entre 9,75% ([10] e 99,36% ([9]. Tendo em conta as diferentes métricas de avaliação, em quatro dos 21 artigos, o modelo com melhor performance foi obtido com *Random Forest* (e.g., [12][14]). Por fim, apenas 10 artigos identificam as variáveis mais importantes para a previsão (e.g., [3][17]), sendo que em 70% dos estudos foram os indicadores financeiros os preditores mais importantes ([12][3]).

C. Avaliação dos resultados dos estudos

Os resultados dos estudos são alvo de análise em termos de contributos, limitações e as pistas de investigação futura (Tabela III). Os contributos são variados, sendo que grande parte dos estudos contribuiu para a literatura com algoritmos de *data mining* ou *machine learning* (e.g., [9][15]) ou a expandiram os fatores associados a falências, insolvências e dificuldades financeiras, para além de indicadores financeiros (e.g., [12][16]). Importa referir que são os investidores, credores e acionistas os *stakeholders* que mais beneficiam com os estudos (e.g., [15][20][24]), apontado por mais de sete destes. No entanto, reguladores, auditores, gestores, entre outros, são também apontados como beneficiários de alguns estudos.

Já quanto às limitações, muitos estudos não as especificam. O maior problema relaciona-se com dados não equilibrados [12]; variáveis que não foram selecionadas pelos métodos de escolha de variáveis utilizados (e.g., [16][10]); dificuldades em perceber o *output* do modelo quanto ao período a que se referia [9]; pequena amostra da classe minoritária [15]. Por último, quanto às pistas de investigação futura, em grande parte estas surgem como consequência das limitações dos diferentes estudos. Há autores que sugerem amplificar os modelos para vários períodos, e não apenas para a previsão do período seguinte (e.g., [9]), ou recomendam a inclusão de indicadores não financeiros [12][21].

TABELA III. AVALIAÇÃO DOS RESULTADOS DOS ESTUDOS

Ref	Contributos	Investigação futura
9	Utilização de técnicas de <i>ML</i>	Contemplar modelos multiperíodos
10	Maior período; Consideração da variável crescimento	Incluir indicadores não financeiros
11	NE	NE

Ref	Contributos	Investigação futura
12	Características não financeiras mais importantes do que financeiras	Incluir indicadores não financeiros
13	Aplicação do método <i>LIME</i> a modelos de <i>black box</i> como o <i>XGBoost</i> e <i>LightGBM</i>	Combinar o modelo utilizado com <i>NNRW</i> para construir um modelo capaz de ser extrapolado
14	Melhoria de tomada de decisão dos financiadores	NE
15	Uso de técnicas de <i>data mining</i>	Avaliar a relação entre fundos governamentais e insolvências das PME no ambiente da COVID-19
16	Novos preditores de dificuldades financeiras	Avaliar os efeitos do aumento do nº de empresas saudáveis no treino; uso de um período mais longo
17	Utilização de 6 algoritmos; métricas de <i>performance</i> para dados desequilibrados; mais variáveis independentes	Construção de um sistema global de <i>rating</i> para os bancos
18	Comparação entre 4 tipos de <i>ANN</i> quando se consideram dados qualitativos	Otimizar os dados com uma técnica particular de otimização heurística
3	Nova perspetiva do desempenho relativo da previsão de dificuldades financeiras	Melhoramento das técnicas de <i>ML</i> a partir da função de extração de características de um <i>DBN</i>
19	Variedade de técnicas e a aplicabilidade do modelo	Incorporação de taxas de crescimento e/ou efeitos temporais; Aplicação em instituições financeiras
20	Utilização de mais de 300 variáveis; e abordagem de <i>data mining</i>	Papel da informação atualizada de uma empresa na precisão da previsão
21	Utilização de novas variáveis (e.g., margem de lucro líquido, retorno do ativo total, ganhos por ação)	Utilização de indicadores não financeiros no modelo de previsão; uso de diferentes países e comparação e contraste entre estes modelos
22	Controlo do <i>tradeoff</i> entre <i>accuracy</i> média e tamanho da <i>DT</i> , que pode ser controlado através do <i>MSP</i>	NE
23	Identificação dos rácios financeiros preditivos com base na literatura e numa análise sequencial de seleção de características	NE
24	Comparação de método estatístico tradicional com abordagem de inteligência artificial	Aplicação de técnicas adicionais de inteligência artificial; Expansão do sistema de modo a lidar com mais conjuntos de dados financeiros
25	Aumento da capacidade dinâmica de aprendizagem das DF de empresas cotadas	Adotar o modelo em empresas cotadas
26	Modelo com melhor <i>performance</i> que os tradicionais	Comparar a abordagem de <i>data mining MCLP</i> com a <i>DT</i> para ver que abordagem é mais eficiente e eficaz na previsão de falências
27	NE	NE
28	Seleção de características com inteligência artificial melhor do que com métodos estatísticos	NE

Notas: ANN- Artificial Neural Networks; DBN- Deep Belief Network; DF- Dificuldades Financeiras; DT- Decision tree; LIME- Local Interpretable Model-Agnostic Explanations; MCLP- Multiple Criteria Linear Programming; ML- Machine Learning; MSP-Minimum Support Parameter; NNRW-Neural Network with Random Weights; PME- Pequenas e Médias Empresas.

D. Avaliação da qualidade dos artigos

Tendo este estudo por base uma RSL, é importante facilitar o trabalho a investigadores e profissionais, classificando-se os artigos de acordo com a qualidade a que respondem a cada questão de investigação formulada (Tabela IV).

TABELA IV. AVALIAÇÃO DA QUALIDADES DOS ARTIGOS NOS 13 ITENS

Ref	Âmbitos e contextos da realização dos estudos					Modelos utilizados na previsão					Avaliação dos resultados			Tot
						das falências/insolvências/dificuldade des financeiras e sua validação								
	1.1	1.2	1.3	1.4	1.5	2.1	2.2	2.3	2.4	2.5	3.1	3.2	3.3	
9	.5	0	1	.5	.5	1	1	1	.5	0	1	1	1	9
10	0	0	1	1	1	1	1	1	1	0	1	1	1	10
11	0	0	1	.5	.5	.5	1	1	.5	0	.5	0	0	5,5
12	0	0	1	.5	.5	1	1	1	.5	0	.5	.5	0	6,5
13	0	0	.5	.5	.5	.5	1	1	.5	0	1	1	0	6,5
14	1	1	1	1	.5	1	1	1	.5	0	.5	.5	0	9
15	.5	0	1	.5	.5	.5	1	1	.5	0	1	1	1	8,5
16	0	0	1	1	1	1	1	1	1	0	.5	1	1	9,5
17	0	0	1	1	1	1	1	1	.5	.5	1	1	1	10
18	0	0	.5	0	.5	1	1	1	.5	.5	.5	1	0	6,5
3	1	0	1	1	.5	.5	1	1	1	0	1	1	0	9
19	0	0	1	1	1	1	1	1	.5	.5	1	1	1	10
20	0	0	1	.5	.5	.5	1	1	.5	0	.5	1	0	6,5
21	1	.5	1	.5	.5	1	1	1	.5	.5	1	1	0	9,5
22	0	0	.5	0	.5	.5	.5	.5	.5	0	.5	.5	0	4
23	1	0	1	.5	.5	1	1	1	.5	0	1	1	0	8,5
24	1	0	1	.5	.5	1	1	1	.5	0	1	1	0	8,5
25	0	0	1	1	.5	.5	.5	0	.5	0	0	.5	0	4,5
26	0	0	1	.5	.5	1	1	1	.5	0	.5	0	0	6
27	0	0	.5	.5	.5	.5	.5	.5	0	0	.5	0	0	3,5
28	0	0	.5	.5	.5	1	1	1	.5	0	.5	0	0	5,5
Tot	6	1,5	18,5	13	12,5	17	19,5	19	11,5	2	15	15	6	

Dos artigos analisados, conclui-se que nenhum tem pontuação máxima (13) e que apenas três obtêm maior pontuação em termos de qualidade, 10 pontos ([10][17][19], sendo que o critério de avaliação que apresenta maior qualidade é o 2.2: Apresenta, descreve e justifica a(s) técnica(s)/ algoritmo(s) utilizada(o) (s)?: A dimensão que se encontra com melhor avaliação é a dos modelos utilizados na previsão das falências/insolvências/ dificuldades financeiras e sua validação, tendo conseguido a maior média de pontuação 13,8, para um máximo de 21. Aliás, é nesta dimensão onde se encontram os dois critérios com melhor pontuação (2.2 e 2.3), onde são alvo de análise os algoritmos utilizados e a comparação entre eles. Em oposição, surge a primeira dimensão a ser avaliada, âmbitos e contextos da realização dos estudos, onde a diferença entre insolvências, falências e dificuldades financeiras (1.2), surge com uma avaliação média muito baixa (1,5, em que apenas dois artigos focam estes aspetos [21][14].

V. CONCLUSÕES

Esta revisão de literatura aumenta o grau de conhecimento sobre predição de insolvências, falências e dificuldades financeiras através da utilização de técnicas avançadas de análise de dados e utilizando indicadores financeiros e não financeiros. Conclui-se que este tema está pouco explorado, havendo poucos artigos publicados em *journals* indexados no WoS, e, assim, é um bom tema para investigar e inovar com, por exemplo, a inclusão de indicadores não financeiros [30].

É importante realçar que já se conseguiram modelos com elevada capacidade preditiva (e.g., [9][18]), mas ainda há espaço para melhorar, incluindo indicadores não financeiros como a opinião do auditor [32] e o género da direção [33]. De facto, as variáveis não financeiras são pouco utilizadas na predição das insolvências, apesar das suas grandes capacidades em distinguir entre empresas ativas e insolventes [12].

Para os gestores, uma boa previsão permite alertar para problemas de viabilidade, de modo que estes consigam delinear estratégias para evitar insolvências e criar as suas estimativas

contabilísticas, aumentando a viabilidade e consistência das mesmas, evitando manipulação [31]. De facto, modelos preditivos baseados em árvores de decisão (ou regras) permitem identificar facilmente as causas para a situação débil em que se encontra a empresa. Por outro lado, no que diz respeito aos utilizadores da informação (e.g., investidores, credores e bancos), os modelos permitem-lhes identificar as empresas com propensões em entrar em insolvência de forma a tomarem melhores decisões de investimento e financiamento [13].

AGRADECIMENTOS

À FCT, projeto estratégico UID/GES/00315/2020. Ao ISCTE-IUL, projeto DAFIM.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] D. Simić, I. Kovačević, e S. Simić, "Insolvency prediction for assessing corporate financial health," *Log J IGPL*, vol. 20, no. 3, pp. 536–549, 2012, doi: 10.1093/jigpal/jzr009.
- [2] Y. N. Isayas, "Financial distress and its determinants: Evidence from insurance companies in Ethiopia," *Cogent Business and Management*, vol. 8, no. 1, 2021, doi: 10.1080/23311975.2021.1951110.
- [3] Y. P. Huang e M. F. Yen, "A new perspective of performance comparison among machine learning algorithms for financial distress prediction," *Applied Soft Computing Journal*, vol. 83, Oct. 2019, doi: 10.1016/j.asoc.2019.105663.
- [4] N. Mizik e D. M. Hanssens, *Handbook of marketing analytics: methods and applications in marketing management, public policy, and litigation support*, Edward Elgar Pub. 2018.
- [5] B. Ma, Y. Wang, e Z. Li, "Application of data mining in basketball statistics," *Applied Mathematics and Nonlinear Sciences*, vol. 0, no. 0, Apr. 2022, doi: 10.2478/amns.2021.2.00182.
- [6] M. M. Ahsan e Z. Siddique, "Machine learning-based heart disease diagnosis: A systematic literature review," *Artif Intell Med*, vol. 128, Jun. 2022, doi: 10.1016/j.artmed.2022.102289.
- [7] A. G. Putrada, M. Abdurrohmah, D. Perdana, e H. H. Nuha, "Machine Learning Methods in Smart Lighting Toward Achieving User Comfort: A Survey," *IEEE Access*, vol. 10, pp. 45137–45178, 2022, doi: 10.1109/ACCESS.2022.3169765.
- [8] S. A. Esteban, E. Urquía-Grande, A. M. de Silva, e R. Pérez-Estébanez, "Big Data, Accounting and International Development: Trends and challenges," *Cuadernos de Gestion*, vol. 22, no. 1, pp. 193–213, 2022, doi: 10.5295/CDG.211513SA.
- [9] H. Kim, H. Cho, e D. Ryu, "Corporate Bankruptcy Prediction Using Machine Learning Methodologies with a Focus on Sequential Data," *Comput Econ*, vol. 59, no. 3, pp. 1231–1249, Mar. 2022, doi: 10.1007/s10614-021-10126-5.
- [10] U. Yousaf, K. Jebran, e M. Wang, "A comparison of static, dynamic and machine learning models in predicting the financial distress of chinese firms," *Romanian Journal of Economic Forecasting*, vol. 25, no. 1, pp. 122–138, 2022.
- [11] D. Bragoli, C. Ferretti, P. Ganugi, G. Marsegua, D. Mezzogori, e F. Zammori, "Machine-learning models for bankruptcy prediction do industrial variables matter," *Spat Econ Anal*, vol. 17, no. 2, pp. 156–177, 2022, doi: https://doi.org/10.1080/17421772.2021.1977377.
- [12] N. Antulov-Fantulin, R. Lagravinese, and G. Resce, "Predicting bankruptcy of local government: A machine learning approach," *J Econ Behav Organ*, vol. 183, pp. 681–699, Mar. 2021, doi: 10.1016/j.jebo.2021.01.014.
- [13] M. S. Park, H. Son, C. Hyun, e H. J. Hwang, "Explainability of Machine Learning Models for Bankruptcy Prediction," *IEEE Access*, vol. 9, pp. 124887–124899, 2021, doi: 10.1109/ACCESS.2021.3110270.
- [14] A. Malakauskas e A. Lakstutiene, "Financial distress prediction for small and medium enterprises using machine learning techniques," *Engineering Economics*, vol. 32, no. 1, pp. 4–14, Feb. 2021, doi: 10.5755/j01.ee.32.1.27382.
- [15] S. Lee, K. Choi, e D. Yoo, "Predicting the insolvency of smes using technological feasibility assessment information and data mining techniques," *Sustainability (Switzerland)*, vol. 12, no. 23, pp. 1–17, Dec. 2020, doi: 10.3390/su12239790.
- [16] X. Tang, S. Li, M. Tan, e W. Shi, "Incorporating textual and management factors into financial distress prediction: A comparative study of machine learning methods," *J Forecast*, vol. 39, no. 5, pp. 769–787, Aug. 2020, doi: 10.1002/for.2661.
- [17] A. Petropoulos, V. Siakoulis, E. Stavroulakis, e N. E. Vlachogiannakis, "Predicting bank insolvencies using machine learning techniques," *Int J Forecast*, vol. 36, no. 3, pp. 1092–1113, Jul. 2020, doi: 10.1016/j.ijforecast.2019.11.005.
- [18] S. Lahmiri e S. Bekiros, "Can machine learning approaches predict corporate bankruptcy? Evidence from a qualitative experimental design," *Quant Finance*, vol. 19, no. 9, pp. 1569–1577, 2019, doi: https://doi.org/10.1080/14697688.2019.1588468.
- [19] F. Barboza, H. Kimura, and E. Altman, "Machine learning models and bankruptcy prediction," *Expert Syst Appl*, vol. 83, pp. 405–417, Oct. 2017, doi: 10.1016/j.eswa.2017.04.006.
- [20] L. Zhou, D. Lu, e H. Fujita, "The performance of corporate financial distress prediction models with features selection guided by domain knowledge and data mining approaches," *Knowl Based Syst*, vol. 85, pp. 52–61, Sep. 2015, doi: 10.1016/j.knsys.2015.04.017.
- [21] R. Geng, I. Bose, e X. Chen, "Prediction of financial distress: An empirical study of listed Chinese companies using data mining," *Eur J Oper Res*, vol. 241, no. 1, pp. 236–247, Feb. 2015, doi: 10.1016/j.ejor.2014.08.016.
- [22] D. L. Olson, D. Delen, e Y. Meng, "Comparative analysis of data mining methods for bankruptcy prediction," *Decis Support Syst*, vol. 52, no. 2, pp. 464–473, Jan. 2012, doi: 10.1016/j.dss.2011.10.007.
- [23] M. Divsalar, H. Roodsaz, F. Vahdatinia, G. Norouzzadeh, e A. H. Behrooz, "A robust data-mining approach to bankruptcy prediction," *J Forecast*, vol. 31, no. 6, pp. 504–523, 2012, doi: 10.1002/for.1232.
- [24] W. sen Chen e Y. K. Du, "Using neural networks and data mining techniques for the financial distress prediction model," *Expert Syst Appl*, vol. 36, no. 2 PART 2, pp. 4075–4086, 2009, doi: 10.1016/j.eswa.2008.03.020.
- [25] J. Sun e H. Li, "Data mining method for listed companies' financial distress prediction," *Knowl Based Syst*, vol. 21, no. 1, pp. 1–5, Feb. 2008, doi: 10.1016/j.knsys.2006.11.003.
- [26] W. Kwak, Y. Shi, J. J. Cheh, e H. Lee, "Multiple Criteria Linear Programming Data Mining Approach: An Application for Bankruptcy Prediction," *Data Mining and Knowledge Management*, vol. 3327, pp. 164–173, 2004, doi: https://doi.org/10.1007/978-3-540-30537-8_18.
- [27] D. P. Foster e R. A. Stine, "Variable selection in data mining: Building a predictive model for bankruptcy," *J Am Stat Assoc*, vol. 99, no. 466, pp. 303–313, Jun. 2004, doi: 10.1198/016214504000000287.
- [28] C. Y. Shirata e T. Terano, "Extracting Predictors of Corporate Bankruptcy: Empirical Study on Data Mining Methods," *Knowledge Discovery and Data Mining, Proceedings*, vol. 1805, pp. 204–207, 2000, doi: https://doi.org/10.1007/3-540-45571-X_25.
- [29] W. H. Beaver, "Financial Ratios As Predictors of Failure," *Empirical Research in Accounting: Selected Studies*, vol. 4, pp. 71–111, 1966, doi: https://doi.org/10.2307/2490171.
- [30] L. Cathcart, A. Dufour, L. Rossi, e S. Varotto, "The differential impact of leverage on the default risk of small and large firms," *Journal of Corporate Finance*, vol. 60, Feb. 2020, doi: 10.1016/j.jcorpfin.2019.101541.
- [31] K. Ding, B. Lev, X. Peng, T. Sun, e M. A. Vasarhelyi, "Machine learning improves accounting estimates: evidence from insurance payments," *Review of Accounting Studies*, vol. 25, no. 3, pp. 1098–1134, Sep. 2020, doi: 10.1007/s11142-020-09546-9.
- [32] M. Stanisic, D. Stefanovic, N. Arezina, e V. Mizdrakovic, "Analysis of Auditor's Reports and Bankruptcy Risk in Banking Sector in the Republic of Serbia," *Amfiteatru Economics*, vol. 15, no. 34, pp. 431–441, 2013, [Online]. Available: https://ssrn.com/abstract=2291496.
- [33] N. Wilson, M. Wright, e A. Altanlar, "The survival of newly-incorporated companies and founding director characteristics," *International Small Business Journal: Researching Entrepreneurship*, vol. 32, no. 7, pp. 733–758, Nov. 2014, doi: 10.1177/0266242613476317.