

Análise e Previsão de Riscos Financeiros: Aplicação de Machine Learning em Subsistemas de Riscos

Luís Miguel Gomes Franco

Dissertação de Mestrado

Orientador na FEUP: Prof. Teresa Bianchi de Aguiar



Mestrado em Engenharia e Gestão Industrial

2023-06-26

Aos meus pais e irmãos

Resumo

Esta dissertação nasce da necessidade de criar um subsistema de risco para diagnosticar a situação financeira das empresas através de informações públicas, com ênfase nas Pequenas e Médias Empresas, com vista a facilitação da avaliação do risco, uma tarefa tendencialmente morosa.

Para endereçar este desafio, foi selecionado um conjunto de rácios financeiros referidos currentemente na literatura financeira. Foram excluídos os rácios financeiros que não podem ser aplicados a empresas não cotadas. Posteriormente, foi desenvolvido um modelo capaz de prever de forma automática o risco financeiro com base nos rácios financeiros, entre outros dados e informações relevantes de cada empresa.

O modelo desenvolvido usa, na sua primeira versão, dados de 604 empresas de 10 setores distintos, distribuídas por 24 países. O ruído inerente desta escolha de dados é propositado, de forma a simular informação desconhecida sobre a empresa. A variável a prever, o risco, classifica as empresas com um rating de 1 a 100 de acordo com o seu nível de risco.

Foi desenvolvida uma Rede Neuronal do tipo *Feed Forward Neural Network* (FNN), treinada com *backpropagation*, e com os parâmetros otimizados com recurso a um algoritmo genético. Este modelo, que prevê o risco financeiro de uma empresa através dos rácios financeiros, tem um RMSE de 13.74, o que foi considerado um resultado positivo, considerando as limitações impostas pelo ruído introduzido e a informação desconhecida sobre a variável a prever.

A metodologia desenvolvida permite também identificar os rácios mais relevantes para a definição do risco financeiro das empresas. De entre os diferentes rácios avaliados, o rácio de Endividamento foi identificado como o fator mais significativo, enquanto o rácio da Rotação de Stocks demonstrou ter a menor influência.

Financial Risk Analysis and Forecasting: Application of Machine Learning in Risk Subsystems

Abstract

This dissertation arises from the need to create a risk subsystem to diagnose the financial situation of companies through public information, with emphasis on Small and Medium Enterprises, to facilitate risk assessment, a task that tends to be time consuming.

To address this challenge, a set of financial ratios currently referred to in the financial literature was selected. Financial ratios that cannot be applied to unlisted firms were excluded. Subsequently, a model was developed that can automatically predict the financial risk based on the financial ratios, among other relevant data and information for each company.

The model developed uses, in its first version, data from 604 companies from 10 different sectors, spread over 24 countries. The noise inherent in this choice of data is intentional, to simulate unknown information about the company. The variable to be predicted, risk, ranks companies with a rating from 1 to 100 according to their risk level.

A Feed Forward Neural Network (FNN) was developed, trained with backpropagation, and with the parameters optimized using a genetic algorithm. This model, which predicts the financial risk of a company through its financial ratios, has an RMSE of 13.74, which was considered a positive result, considering the limitations imposed by the introduced noise and the unknown information about the variable to be predicted.

The methodology developed also allows us to identify the most relevant ratios for defining the financial risk of companies. Among the different ratios evaluated, the Debt ratio was identified as the most significant factor, while the Stock Turnover ratio proved to have the least influence.

Agradecimentos

Com o término desta dissertação, que marca a conclusão de mais uma etapa. Desejo agradecer:

À Professora Teresa Bianchi de Aguiar, que foi a minha orientadora nesta dissertação, pela paciência, tempo e apoio dado durante o trabalho.

À Empresa RMP, em especial ao Sérgio Resende, que me recebeu e proporcionou a oportunidade de realizar este trabalho.

À minha família, em especial aos meus pais e irmãos, que sempre me apoiaram e incentivaram, mesmo quando a distância é longa.

Por fim a todos aqueles os que de forma influenciaram o meu desenvolvimento durante o meu percurso.

Índice de Conteúdos

1. Introdução	1
1.1 Enquadramento do projeto.....	1
1.2 Objetivos do projeto	1
1.3 Método seguido no projeto.....	2
1.4 Estrutura da dissertação	2
2. Enquadramento Teórico.....	3
2.1 Gestão de Riscos em Empresas.....	3
2.1.1 Os <i>Frameworks</i> principais da ERM	4
2.2 Risco Financeiro	6
2.3 Rácios Financeiros.....	7
2.3.1 Uso dos rácios e as suas limitações.....	7
2.4 Redes Neuronais Artificiais (ANN)	8
2.4.1 FeedFoward Neural Networks	9
2.4.2 Função de Ativação	9
2.4.3 Função de Perda	10
2.4.4 Otimizador	11
2.4.5 K-Fold Cross Validation	11
2.4.6 Algoritmo Genético	12
2.4.7 Estudos com Redes Neuronais Artificiais no contexto de risco financeiro.....	13
3. Descrição do problema	15
3.1 RMP e respetivo ERM.....	15
3.2 Limitações do ERM	16
3.3 Solução	17
4. Método e Resultados	19
4.1 Apresentação geral do método	19
4.2 Base de Dados.....	19
4.3 Escolha dos rácios	21
4.3.1 Rácios de Liquidez	21
4.3.2 Rácios de Z-Score	22
4.3.3 Rácios de Solvência	22
4.3.4 Rácios de Rentabilidade	23
4.3.5 Rácio de Fiscalidade.....	23
4.3.6 Rácios de Atividade	24
4.3.7 Rácios de Risco.....	24
4.3.8 Corelação entre as variáveis	25
4.4 Ferramentas e Software.....	26
4.5 Construção da ANN	26
4.6 Resultados	29
4.6.1 Importância dos rácios.....	30
4.7 Análise dos Resultados.....	31
4.7.1 Análise dos Resultados do Modelo.....	31
4.7.2 Análise da Importância dos Rácios Financeiros	31
4.7.3 Comparação com outros estudos	32
4.7.4 Limitações dos Resultados	33
5. Conclusões e perspetivas de trabalho futuro.....	34
5.1 Conclusão	34
Bibliografia.....	35

Siglas

AdaGrad - *Adaptive Gradient Algorithm*

Adam - *Adaptive Moment Estimation*

AdaBoost - *Adaptive Boosting*

AI - Inteligência artificial

AEP - Associação Empresarial de Portugal

ANN - Redes Neurais Artificiais

CART - *Classification and Regression Trees*

CNN- *Convolutional Neural Network*

COSO - Committee of Sponsoring Organizations of the Treadway Commission

CV - *Cross Validation*

DNN - *Deep Neural Networks*

DT - Árvores de Decisão

EBITDA - *Earnings before interest, taxes, depreciation, and amortization*

ERM - Gestão de Riscos em Empresas.

FCNN - *Fuzzy Convolutional Neural Network*

FNN - *Feedforward Neural Network*

IES - Informação Empresarial Simplificada

ISCAP - Instituto Superior de Contabilidade e Administração do Porto

ISO - International Organization for Standardization

LDA- Linear Discriminant Analysis

LR - Regressão Logística

LRP - *Layer-wise Relevance Propagation*

ML - *Machine Learning*

MLP - *Multilayer Perceptron*

MSE - Erro Quadrático Médio

PMEs - Pequenas e Médias Empresas

P2P - Peer-to-Peer

PLS-DA - *Partial Least Squares Discriminant Analysis*

REL - *Rectified Linear Unit*

ROA - Retorno Sobre os Ativos

ROE - Rentabilidade dos Capitais Próprios

RMP - Risk Managements Projects

RMSE - Raiz do Erro Médio Quadrático

SELU - *Scaled Exponential Linear Unit*

Índice de Figuras

Figura 1- Esquema da Avaliação do Risco	5
Figura 2 - Framework para gestão de risco em empresas	6
Figura 3 - Estrutura de uma DNN.....	9
Figura 4 - Exemplo de uma divisão de dados com $k = 5$	12
Figura 5 - Estrutura de funcionamento de um algoritmo genético padrão.....	13
Figura 6 - Número de empresas por país	20
Figura 7 - Número de empresas por setor	20
Figura 8 - Distribuição da variável a prever	21
Figura 9 – Matríz de correlações.....	26
Figura 10 – Melhoria da função objetivo com o número de iterações efetuadas pelo algoritmo genético	28
Figura 11 – Perda média do treino e validação com o número de <i>epochs</i>	30

Índice de Tabelas

Tabela 1 - Esquema de avaliação de rating da empresa Moody's	17
Tabela 2 - Hiperparâmetros treinados pelo algoritmo genético	27

1. Introdução

Neste capítulo é feita a introdução à dissertação, fazendo um enquadramento do projeto, o método seguido assim como a estrutura da dissertação.

1.1 Enquadramento do projeto

Esta dissertação nasce de uma parceria entre a RMP (Risk Managements Projects), AEP (Associação Empresarial de Portugal) e o ISCAP (Instituto Superior de Contabilidade e Administração do Porto), com o intuito de criar um observatório de risco.

A RMP - Risk Management Projects, é uma empresa de gestão de riscos que visa diagnosticar, melhorar e monitorizar continuamente os níveis de risco das empresas.

A gestão de risco em empresas é fundamental para garantir o sucesso das empresas, no entanto a RMP está com dificuldades em conseguir que as empresas se juntem ao projeto, nomeadamente devido à complexidade inerente ao preenchimento da informação necessária para o cálculo dos diversos riscos avaliados. Para facilitar a interação com as empresas foi pensado desenvolver um subsistema de diagnóstico baseado em informações públicas, que facilite a abordagem às empresas.

1.2 Objetivos do projeto

Esta dissertação tem como objetivo contribuir para a construção do subsistema de diagnóstico baseado em informações públicas. Em concreto, o objetivo é desenvolver um protótipo deste ecossistema, capaz de processar um conjunto de dados relativos às empresas, nomeadamente performance financeira, e de retornar um grau de risco associado. Para tal, para além da informação da própria empresa, deve-se ter em consideração o ecossistema em que a empresa estará inserida, como por exemplo a concorrência. O âmbito deste projeto está limitado a PMEs (pequenas e médias empresas) e a riscos financeiros, um dos ecossistemas de risco avaliados no âmbito do observatório de risco desenvolvido pela RMP.

Espera-se então com este trabalho:

- Identificação dos principais dados públicos a utilizar para identificação dos riscos financeiros;
- Metodologia para o cálculo dos riscos financeiros;
- Construção de um subsistema de diagnóstico do risco financeiro

1.3 Método seguido no projeto

A primeira parte do projeto foi a consulta da bibliografia, de forma a compreender o que era a ERM (Gestão de Riscos em Empresas).

A segunda parte passou por analisar a informação pública das empresas, concluindo que a melhor forma de analisar as PME's (Pequenas e Médias Empresas) seria através do seu IES (informação empresarial simplificada).

A terceira parte do projeto foi a consulta bibliográfica sobre análise financeira, durante a qual foi explorada a análise da informação contida no IES e construído um subsistema de diagnóstico baseado em análise financeira.

A quarta parte do projeto foi descobrir uma forma de melhorar o subsistema através de consulta bibliográfica, chegando à conclusão que utilizaríamos ANN (*Rede Neuronal Artificial*), também foi decidido que apenas utilizaríamos rácios.

A quinta e última parte do projeto foi desenvolver uma FNN (*Feedforward Neural Network*), usando dados de uma base de dados que a RMP tem acesso de forma a desenvolver o modelo para ser aplicado no subsistema de diagnóstico.

1.4 Estrutura da dissertação

Esta dissertação está dividida em 5 capítulos:

O 1º capítulo faz uma introdução ao projeto, apresentando o enquadramento e objetivos do projeto, o método seguido e a estrutura da dissertação.

O 2º capítulo faz o enquadramento teórico, começando pela ERM, passando para o risco financeiro e finalizando no enquadramento das ANN.

O 3º capítulo aborda o problema, apresentando a empresa e o seu sistema de análise de risco. Posteriormente, é feita uma análise do problema através de uma introdução aos rácios e por fim apresentando os objetivos e a solução.

O 4º capítulo é sobre o método e os resultados. Começa com uma descrição da base de dados, passando para a escolha dos rácios, seguindo-se para a correlação entre as variáveis. São descritas as ferramentas utilizadas, principalmente para a construção da ANN, sendo este o tema seguinte abordado. O capítulo finaliza com os resultados obtidos e a sua análise.

O 5º capítulo é a conclusão do projeto, onde são apresentadas as conclusões da dissertação e os trabalhos futuros.

2. Enquadramento Teórico

Neste capítulo será feita uma introdução teórica aos conteúdos desta dissertação. Primeiro é feito uma introdução à gestão de riscos em empresas, onde são apresentados os dois *frameworks* mais conhecidos. Seguidamente é abordado o risco financeiro. Por fim, é feita uma introdução às ANN, entrando em detalhe sobre a construção de uma ANN para efetuar problemas de regressão.

2.1 Gestão de Riscos em Empresas

A ERM (Gestão de Riscos em Empresas) incorpora uma abordagem integral que identifica, avalia e gere riscos que podem interferir com os objetivos de uma empresa, com o objetivo de criar valor para a empresa, através da realização dos seus objetivos (Sprčić et al. 2015).

A ERM nasceu no meio financeiro e nesta altura analisava os riscos de catástrofe e os riscos financeiros. Atualmente os riscos são tipicamente classificados em 4 categorias: financeiro, operacional, estratégico e catástrofe (McShane 2018).

Historicamente as empresas têm gerido os diferentes tipos de risco separadamente, por exemplo o departamento financeiro gere riscos associados a variações nas taxas de juro enquanto o operacional gere riscos relacionados à qualidade do produto. Devido a esta separação, cada sector acabou por desenvolver ferramentas e práticas independentes (Bromiley et al. 2015).

A partir do meio da década de 70 começou a existir defensores de uma abordagem integral à gestão de riscos. No entanto, o primeiro artigo académico sobre o tema é apenas publicado no ano 2001(Bromiley et al. 2015). De acordo com o Economist Intelligence Unit, a má gestão de risco foi uma das principais causas da crise económica de 2008 (Ahmad et al. 2014).

Atualmente vários estudos comprovam a relação positiva entre uma abordagem integral à gestão de risco e a performance das empresas, tais como:

Yun (2023), analisou os dados da indústria de seguros dos EUA para investigar o impacto da adoção da ERM na gestão de riscos corporativos. Empresas que adotam a ERM utilizam menos seguros e mais derivativos (instrumentos financeiros que derivam o seu valor de um ativo subjacente, como por exemplo contratos a termo), em comparação com outras empresas. No entanto o estudo foi feito com uma pequena amostra.

Malik et al (2020) estudaram a relação entre ERM e o desempenho da empresa, medido por Tobin's Q. Foi concluído que a implementação de ERM aumenta o desempenho da empresa. O estudo também concluiu que a existência de um comité de risco na direção melhora a implementação do ERM e o desempenho da empresa.

Callahan e Soileau (2017) usaram um conjunto de dados baseado em questionários vinculados a dados arquivados das empresas. Foi concluído que a ERM aumenta o desempenho

operacional da companhia, medido por ROA (Retorno Sobre os Ativos) e ROE (Rentabilidade dos Capitais Próprios)

Al-Amri e Davydov (2016) estudaram a relação entre ERM e as perdas operacionais. Foi concluído que empresas com ERM tem uma redução na frequência de perdas operacionais em 65% e de 35% na severidade das perdas operacionais.

Mohammed e Knapkova (2016) estudaram a relação entre ERM e o desempenho da empresa usando uma regressão logística, concluindo que a ERM aumentava o desempenho da empresa.

2.1.1 Os *Frameworks* principais da ERM

De acordo com a ISO (2009), o *framework* para a ERM desta organização foi lançado em 2009. Este contém diretrizes genéricas e princípios que podem ser aplicados a qualquer indústria ou sector. A avaliação de risco contém os seguintes componentes observados na Figura 1:

- Comunicação e consulta: A organização deve desenvolver um plano de comunicação nos estágios iniciais de forma a manter atualizadas as partes interessadas internas e externas. Este plano deve comunicar os problemas relacionados com o risco, assim como as consequências e as medidas contra este.
- Estabelecimento do contexto: Esta etapa envolve compreender os fatores internos e externos que podem influenciar a gestão de riscos, definir o âmbito da gestão de riscos e estabelecer critérios de risco.
- Identificação de Riscos: O processo de identificação de riscos consiste em identificar sistematicamente as fontes potenciais de risco, eventos e suas causas. Devem ser incluídas fontes de risco internas e externas, além de se incentivar a participação das partes interessadas.
- Análise de Riscos: A análise de riscos envolve avaliar a probabilidade e o impacto dos riscos identificados. Essa etapa inclui análises qualitativas e/ou quantitativas para determinar a importância dos riscos e priorizá-los com base nas potenciais consequências.
- Avaliação de Riscos: A avaliação de riscos envolve comparar os resultados da análise de riscos com os critérios de risco estabelecidos para determinar a aceitabilidade dos riscos. Isso ajuda as organizações a compreender o perfil de risco geral e tomar decisões informadas em relação ao tratamento dos riscos.
- Tratamento de Riscos: O tratamento de riscos concentra-se na seleção e implementação de respostas adequadas aos riscos, com base na propensão para o risco e nos objetivos da organização. As opções de tratamento de riscos incluem evitar, transferir, mitigar ou aceitar os riscos.
- Monitorização e Revisão: A monitorização contínua e a revisão do processo de gestão de riscos ajudam a garantir a eficácia e a melhoria contínua das práticas de gestão de riscos. Deve incluir a avaliação regular dos tratamentos de risco, a monitorização das mudanças no panorama de riscos e o ajuste do *framework* de gestão de riscos, conforme necessário.




Figura 1- Esquema da Avaliação do Risco (ISO 2009)

Outro *framework* para a ERM é o do COSO (2017), lançado em 2004 e com a sua última atualização em 2017, que pode ser observado na Figura 2. Este *framework* é um conjunto de princípios organizados em 5 componentes:

- **Ambiente interno:** Esta componente diz respeito à cultura, ética, valores e integridade da organização. É crucial ter uma estrutura organizacional adequada, com uma administração comprometida, além de políticas e práticas que promovam a responsabilidade e a responsabilização.
- **Definição de objetivos:** Os objetivos e metas da organização devem ser claramente estabelecidos e alinhados com a sua missão e estratégia. É necessário identificar e avaliar os riscos que podem prejudicar a capacidade da organização em alcançar esses objetivos.
- **Identificação de eventos:** Neste componente, a organização identifica eventos internos e externos que possam prejudicar a sua capacidade de atingir os objetivos estabelecidos. Esses eventos são analisados em termos de probabilidade de ocorrência e impacto potencial que podem ter nos objetivos.
- **Avaliação de riscos:** Os riscos identificados são avaliados em relação à sua magnitude, levando em consideração a probabilidade de ocorrência e o impacto potencial. Essa avaliação auxilia na determinação da prioridade de cada risco e na alocação adequada de recursos para a sua mitigação.
- **Resposta ao risco:** Com base na avaliação de riscos, a organização desenvolve estratégias para lidar com os riscos identificados. Essas estratégias podem incluir evitar, mitigar, transferir ou aceitar os riscos. É importante estabelecer planos de ação claros e responsabilidades bem definidas para a implementação das estratégias de resposta.

Além destes componentes, este *framework* enfatiza a importância de uma comunicação eficaz e de um processo contínuo de monitorização. A comunicação clara e transparente é fundamental para garantir que todas as partes interessadas estejam cientes dos riscos e das estratégias de gestão adotadas. A monitorização contínua garante que as estratégias de gestão de riscos sejam eficazes e que as mudanças no ambiente de risco sejam identificadas e tratadas de forma oportuna.



Figura 2 - *Framework* para gestão de risco em empresas (COSO 2017)

2.2 Risco Financeiro

O risco financeiro, tem sido muito estudado ao longo dos anos devido a ser uma área de interesse para investidores, gestores, agências de rating, bancos e às próprias empresas em dificuldade financeira. O risco financeiro reflete a dificuldade de as empresas fazerem face às suas obrigações financeiras, por isso é também referido em estudos como dificuldades financeiras em empresas. As empresas entram em dificuldades financeiras devido a dificuldades no setor em que estão envolvidos ou devido à má gestão, sendo esta a principal causa (Whitaker 1999).

Os bancos, enquanto principal fonte de financiamento, estão especialmente interessados no risco financeiro, de forma a minimizarem o incumprimento por parte das empresas que solicitam crédito. Existem muitos modelos de risco de crédito, entre os quais o risco de crédito desenvolvido em 1997 pela Credit Suisse Financial Products, de nome CreditRisk+, que se concentra apenas no risco de incumprimento. A McKinsey & Company, uma empresa de consultoria, também tem o seu próprio modelo de risco, denominado CreditPortfolioView, em que relaciona o risco de incumprimento com fatores macroeconómicos. No entanto, não existe evidência que estas propostas sejam melhores que um modelo simples *Bayesian* construído através da experiência do departamento de crédito do banco (Crouhy et al. 2000).

Existem vários estudos que preveem a falência das empresas. Um dos mais conhecidos é o estudo realizado por Altman (1968) que desenvolveu um modelo para prever o risco de falência das empresas à qual chamou Z-score. O modelo classificou corretamente 95% das empresas de uma amostra equilibrada (50/50) de um total de 66 empresas. O modelo contém 5 rácios financeiros e foi obtido através do uso da regressão linear. O estudo do Z-Score é também importante porque constitui a primeira evolução no estudo das falências de empresas. Antes usava-se uma análise univariada avançada e a partir do Z-Score passam a destacar-se estudos com análise discriminante múltipla, que posteriormente evoluíram para análises utilizando modelos logit e probit, posteriormente para o uso do algoritmo de particionamento recursivo e finalmente para as redes neuronais artificiais, de sigla ANN - *Artificial Neural Network*. (Fanning e Cogger 1994; Anjum 2012).

Um dos campos que ganhou destaque após a crise financeira de 2008 foi a criação de modelos de *machine learning* para detetar antecipadamente as dificuldades financeiras das empresas. Zhang et al (2023) usaram o *XGBoost*, que alcançou um desempenho melhor que a regressão logística e a *random forest* ao analisar empresas do setor da indústria na China. Neste estudo foram usados 20 rácios financeiros e 5 rácios não financeiros. X. Sun e Lei (2021) usaram 19

rácios financeiros para detetar antecipadamente as dificuldades financeiras de empresas de mineração na China, para tal usaram uma rede neuronal treinada com *backpropagation*.

2.3 Rácios Financeiros

Os rácios financeiros são relações numéricas utilizadas na análise financeira para avaliar a saúde e o desempenho de uma empresa. Essas relações são estabelecidas através do agrupamento de contas do balanço, da demonstração de resultados e da demonstração de fluxos de caixa, bem como de outras grandezas económico-financeiras. Os rácios permitem uma avaliação quantitativa da liquidez, solvabilidade, rentabilidade e eficiência operacional de uma empresa. São frequentemente referidos como índices, coeficientes, quocientes ou indicadores. A análise dos rácios financeiros proporciona perspetivas importantes para a tomada de decisões e a gestão financeira de uma organização, sendo o método mais utilizado na análise financeira (Neves 2017).

Os rácios são muito usados por gestores, credores, reguladores e investidores uma vez que quando são bem usados podem revelar muitas informações acerca das empresas, no entanto é melhor olhar para estes apenas como uma ferramenta de diagnóstico (Higgins et al. 2009).

2.3.1 Uso dos rácios e as suas limitações

De acordo com Neves (2017), os rácios têm vários usos, tais como:

- **Análise de tendências:** Os rácios financeiros são ferramentas úteis para identificar tendências ao longo do tempo. Ao comparar os rácios em diferentes períodos, é possível analisar o desempenho da empresa no passado e projetar possíveis cenários futuros. Com base nesta análise, os investidores e gestores podem fazer previsões sobre o crescimento futuro da empresa. No entanto, é importante lembrar que os rácios financeiros são baseados em dados históricos e podem não captar mudanças recentes ou eventos imprevistos que possam influenciar o desempenho da empresa. Eventos extraordinários, mais recentes como o COVID19 e a guerra na Ucrânia, têm um profundo impacto nas empresas, fazendo com que os rácios calculados antes destes eventos não sejam capazes de prever o futuro da empresa em países afetados pelo problema.
- **Comparação setorial:** Os rácios financeiros são frequentemente utilizados para comparar o desempenho de uma empresa com outras do mesmo setor. Essa comparação permite identificar as forças e fraquezas relativas da empresa em relação aos seus concorrentes e avaliar a eficiência operacional. Além disso, a comparação setorial pode ajudar a identificar as melhores práticas utilizadas pelas empresas líderes do setor. No entanto, é importante ter em mente que diferentes empresas podem adotar políticas de contabilidade diferente, o que pode distorcer as comparações. Portanto, é fundamental considerar as diferenças entre as empresas antes de tirar conclusões definitivas. A comparação setorial destaca-se também porque o valor dos rácios pode mudar de significado de acordo com o setor e a economia do país. Ou seja, mesmo análises setoriais com base em rácios devem ser feitas entre empresas que trabalham em economias semelhantes.
- **Análise de solvência e liquidez:** Os rácios financeiros são amplamente utilizados para avaliar a capacidade de uma empresa de cumprir as suas obrigações de curto e longo prazo. Rácios como os rácios de liquidez e os rácios de solvência fornecem informações sobre a capacidade da empresa em pagar suas dívidas. No entanto, estes rácios não levam em consideração a qualidade dos ativos ou a capacidade de gerar

fluxo de caixa no futuro. Portanto, é importante complementar a análise com outras métricas e informações relevantes.

- **Avaliação do desempenho operacional:** Os rácios financeiros são utilizados para avaliar a eficiência operacional de uma empresa. Rácios como os rácios de rentabilidade e os rácios de atividade fornecem informação sobre a eficiência das empresas na geração de lucro e utilização dos recursos. No entanto, esses rácios podem ser influenciados por fatores externos, como mudanças na economia ou na indústria. Portanto, é importante considerar o contexto em que a empresa opera e avaliar os fatores externos que possam influenciar seu desempenho

Resumindo, os rácios financeiros desempenham um papel fundamental na análise financeira, fornecendo informações sobre o desempenho e a saúde financeira de uma empresa. No entanto, é importante reconhecer as suas limitações e complementar a análise com outras métricas e informações relevantes para obter uma visão mais completa e precisa.

2.4 Redes Neurais Artificiais (ANN)

A Inteligência artificial (AI) constitui os sistemas capazes de aprender, raciocinar e tomar decisões sem intervenção humana. Dentro da AI temos o *Machine Learning* (ML), que permite aos computadores aprender a partir de dados. Utiliza algoritmos para identificar padrões e tomar decisões com base nestes (Kumar et al. 2012).

As Redes Neurais artificiais, em inglês *Artificial Neural Networks* (ANN), uma subclasse de ML, são modelos computacionais inspirados no funcionamento do cérebro humano. Uma ANN é composta por camadas de neurónios (nas ANN os neurónios são conhecidos como nós) interconectados, que processa e transforma os dados. As ANN são capazes de realizar várias tarefas como por ex. identificar padrões complexos, processamento de linguagem, reconhecimento de imagens e previsão de resultados (Guha et al. 2022).

Uma ANN é constituída por 3 camadas que são constituídas por Nós. A primeira camada (camada de entrada) é onde são colocados os dados externos, na segunda camada (camada oculta) é feita a computação dos dados e a terceira camada retorna os resultados (camada de saída) (Guha et al. 2022).

Os Nós são considerados processadores muito simples, cada um tendo uma pequena quantidade de memória local. Durante o treino, são atualizados dinamicamente os pesos aplicados às suas conexões, de acordo com a sua relevância. A ANN propaga a sua informação desde a camada de entrada até à camada de saída. Quando o resultado à saída é diferente do desejado, um erro é calculado e propagado para trás modificando-se o peso dos nós. Este processo é conhecido como *Backpropagation* (Kumar et al. 2012).

Existem diversos métodos de aprendizagem utilizados nas ANN. A aprendizagem supervisionada é um dos métodos mais comuns, onde a rede é treinada com dados de entrada e saída desejados, permitindo, após a aprendizagem, a previsão para novos dados de saída. A aprendizagem não supervisionada busca encontrar padrões e estruturas nos dados de entrada sem o uso de rótulos. A aprendizagem por reforço é outra abordagem, em que a rede aprende através de recompensas e punições (Choi et al. 2020).

As *Deep Neural Networks* (DNN) são redes neuronais artificiais que contêm mais que uma camada oculta, não existindo um limite para o número de camadas ocultas, a Figura 3 mostra a estrutura de uma DNN. Estas redes neuronais foram propostas de forma a fazer modelos com maior poder de previsão. Uma das críticas feitas a este tipo de modelo é que um elevado número de camadas ocultas torna o modelo opaco, ou seja, difícil de explicar. Isto acontece devido a várias razões, como por exemplo a não linearidade do modelo que acontece devido a alguns nós ativarem para certas variáveis e outros ativam para a globalidade das variáveis. No

entanto com o uso de algoritmos como por exemplo o LRP (*Layer-wise Relevance Propagation*) é possível explicar as DNN assim como outros modelos não lineares (Samek et al. 2021).




Figura 3 - Estrutura de uma DNN in <https://www.freecodecamp.org/news/want-to-know-how-deep-learning-works-heres-a-quick-guide-for-everyone-1aedeca88076/>, consultado em 2023-6-2

2.4.1 FeedFoward Neural Networks

As *Feedforward Neural Networks* (FNN) são um tipo de rede neuronal em que os dados se propagam apenas na direção da camada de entrada para a camada de saída. Esta arquitetura torna a passagem de informação mais direta, simples e eficiente em tarefas de classificação e regressão. As FNN não possuem conexões recorrentes, o que limita a sua capacidade de modelar dependências temporais e sequências de dados (Kwok e Yeung 1997).

Backpropagation foi aplicado com sucesso para otimizar as FNN em vários tipos problemas. As FNN são conhecidas como um aproximador universal, o teorema de Kolmogorov mostrou que uma simples FNN com apenas uma camada oculta e um número finito de nós, com a função de ativação *sigmoid*, poderia aproximar qualquer função contínua (Ojha et al. 2017).

2.4.2 Função de Ativação

As funções de ativação desempenham um papel crucial nas ANN. Estas funções desempenham a função de introduzir não linearidade nas saídas das camadas, permitindo que as ANN aprendam padrões complexos nos dados. Existem várias funções de ativação disponíveis, como a função *sigmoid* (1), que foi muito popular no início das ANN. Esta função comprime os valores de entrada em um intervalo entre 0 e 1. A função *sigmoid* é não linear por natureza e possui uma derivada suave. No entanto, a faixa de saída também é comprimida, o que resulta no desaparecimento do gradiente, especialmente em DNN. Este comportamento torna a otimização das DNN muito difícil a partir de um certo ponto (Rasamoelina et al. 2020).

$$f(x) = \frac{1}{1 + e^{-x}} \quad (1)$$

A função de ativação ReLU (*Rectified Linear Unit*) (2) é a função mais utilizada nas DNN. A ReLU torna todos os valores negativos em zero e mantém os valores positivos inalterados. Esta função é capaz de ter zeros verdadeiros, o que permite a presença de muitos nós com valores nas suas camadas ocultas. No entanto, a maior limitação da ReLU é que quando um nó adquire um valor negativo, este dificilmente se recupera (Rasamoelina et al. 2020).

$$f(x) = \max(0, x) \quad (2)$$

A função de Ativação SELU (*Scaled Exponential Linear Unit*) (3) possui propriedades intrínsecas que promovem a normalização dos valores e demonstra um desempenho satisfatório em FNN (Rasamoelina et al. 2020).

$$f(x) = \gamma * (\max(0, x) + \min(0, \alpha(\exp(x) - 1))) \quad (3)$$

A função *Swish* (4) é uma função não-monótona e suave que demonstra consistentemente um desempenho igual ou superior à função ReLU em DNN. Esta função é caracterizada por ser ilimitada acima e limitada abaixo (Rasamoelina et al. 2020).

$$f(x) = \frac{x}{1 + e^{-\beta x}} \quad (4)$$

2.4.3 Função de Perda

As funções de perda desempenham um papel fundamental no contexto das ANN, pois permitem medir o desempenho durante o treino do modelo. Existem várias opções disponíveis, cada uma com suas características e usos específicos. De seguida são apresentadas quatro funções recorrentemente utilizadas em problemas de regressão.

A função do erro quadrático médio (MSE) (5) é amplamente usada em problemas de regressão. Esta avalia a média dos erros ao quadrado entre o valor real y e o valor previsto $f(x)$ da amostra x . A função de perda erro quadrático médio é sensível a valores discrepantes, uma vez que o seu crescimento é rápido quando o erro é grande. No entanto, ela proporciona convergência rápida e alta precisão ao modelo (Wang et al. 2022).

$$L(y, f(x)) = \frac{1}{N} \sum_{i=1}^N (y_i - f(x)_i)^2 \quad (5)$$

A função do erro médio absoluto (6) mede a média do valor absoluto do erro entre o valor real y e o valor previsto $f(x)$ da amostra x . A função de perda do erro médio absoluto não penaliza tanto os valores discrepantes como a função de perda quadrática. Contudo, ela não é diferenciável quando o erro se aproxima de zero e possui um gradiente fixo, o que pode afetar a eficiência da solução do modelo (Wang et al. 2022).

$$L(y, f(x)) = \frac{1}{N} \sum_{i=1}^N |y_i - f(x)_i| \quad (6)$$

A função de Huber (7) é uma combinação da função de perda quadrática e da função de perda absoluta. A função de perda Huber incorpora as vantagens das funções de perda quadrática e absoluta, sendo diferenciável em todos os pontos, porém requer iterações constantes para ajustar o parâmetro δ (Wang et al. 2022).

$$L_{\delta}(y, f(x)) = \begin{cases} \frac{1}{2}(y - f(x))^2, & \text{se } |y - f(x)| \leq \delta \\ \delta|y - f(x)| - \frac{1}{2}\delta^2, & \text{caso contrário, onde } \delta > 0 \end{cases} \quad (7)$$

A função log-cosh (8) corresponde ao logaritmo do cosseno hiperbólico do erro. Esta função apresenta características semelhantes à função de perda Huber e é resistente a outliers (Wang et al. 2022).

$$L(y, f(x)) = \log(\cosh(f(x) - y)) \quad (8)$$

2.4.4 Otimizador

O SGD (*Stochastic Gradient Descent*) é um dos otimizadores mais simples e amplamente utilizados em redes neurais. Este baseia-se na atualização iterativa dos pesos dos nós utilizando o gradiente da função de perda em relação aos parâmetros. O SGD tem-se mostrado eficiente na abordagem de problemas de regressão, nos quais o objetivo é minimizar a discrepância entre os valores previstos e os valores reais. No entanto, o SGD pode enfrentar desafios relacionados à convergência rápida e à identificação de mínimos locais (S. Sun et al. 2020).

O AdaGrad (*Adaptive Gradient Algorithm*), é um otimizador que se destaca por adaptar a taxa de aprendizagem de cada parâmetro individualmente. Essa abordagem é realizada por meio de uma atualização ponderada com base na frequência das atualizações anteriores, conferindo maior importância aos parâmetros (valores ajustáveis ou ponderações que são aprendidos durante o processo de treino do modelo) menos frequentes. Essa característica permite que o AdaGrad lide de maneira mais eficiente com os problemas nos quais os parâmetros apresentam escalas amplamente diferentes. No entanto, o AdaGrad pode sofrer com uma diminuição excessiva da taxa de aprendizagem ao longo do tempo, resultando em uma convergência lenta (S. Sun et al. 2020).

O Adam (*Adaptive Moment Estimation*) é um otimizador que combina as propriedades do SGD e do AdaGrad. Este mantém uma taxa de aprendizagem adaptativa para cada parâmetro, assim como o AdaGrad, e incorpora um termo de momento para acelerar o processo de convergência, similar ao SGD. O Adam tem-se mostrado eficiente em problemas de regressão, especialmente em situações em que os dados apresentam um elevado nível de ruído ou quando há um grande número de parâmetros a serem otimizados (S. Sun et al. 2020).

2.4.5 K-Fold Cross Validation

A validação cruzada, em inglês *cross-validation* (CV) é uma técnica usada para resolver um dos problemas mais importantes em ML, o *Overfitting*, em que o modelo gerado tem um grande enviesamento (*bias*) em relação aos dados utilizados para o treino, o que reduz a sua generalização. Além do *overfitting* temos problemas associados a incertezas nos dados e de acordo com estudos, CV com K-fold, ajuda a minimizar o problema (Vu et al. 2022).

Ao treinar um modelo, os dados são divididos normalmente em treino e teste, por exemplo 80/20. A CV K-fold consiste em dividir os dados em K partes iguais, como pode ser observado na Figura 4. Posteriormente, o modelo é treinado K vezes. Em cada treino são usadas K-1 partes para treinar e 1 parte para testar. Cada parte é usada uma única vez como teste. A avaliação do modelo pode ser inferida como a avaliação média dos K testes (Jiang e Chen 2016).




Figura 4 - Exemplo de uma divisão de dados com $k = 5$ in <https://didatica.tech/o-pacote-caret-linguagem-r/>, consultado em 2023-6-25

2.4.6 Algoritmo Genético

Para ter uma boa ANN é preciso selecionar os hiperparâmetros (valores pré-definidos que controlam o comportamento e a arquitetura do modelo) certos. O Algoritmo Genético tem melhor performance que uma *Grid Search* e que o algoritmo *Bayesian* quando há muitos Hiper parâmetros (Alibrahim e Ludwig 2021).

O Algoritmo Genético é um algoritmo de otimização meta heurístico, inspirado pelos mecanismos inerentes à teoria da evolução, como a seleção natural e a mutação genética, cuja estrutura de funcionamento pode ser observada na Figura 5 (Alibrahim e Ludwig 2021). O algoritmo avalia os indivíduos, em que cada indivíduo representa uma solução candidata no espaço de busca, de acordo com uma função que avalia a qualidade da solução. Após selecionar os melhores indivíduos é gerada uma nova população. A nova população tem novos indivíduos, descendentes dos melhores indivíduos da população anterior (combina características dos melhores indivíduos) e mutações dos melhores indivíduos (um certo número de parâmetros do individuo são alterados com base numa probabilidade pré-definida). Esta população é reavaliada e dá origem a uma nova população. Este processo repete-se até à condição de término – tipicamente, tempo máximo de execução ou percentagem de melhoria face à população anterior (Alibrahim e Ludwig 2021).




Figura 5 - Estrutura de funcionamento de um algoritmo genético padrão in <https://bioinfo.com.br/algoritmos-geneticos/>, consultado em 2023-6-25

2.4.7 Estudos com Redes Neurais Artificiais no contexto de risco financeiro

No campo do risco financeiro e previsão de riscos, várias técnicas têm sido exploradas para melhorar a precisão e fiabilidade dos modelos. Nesse sentido, vários estudos recentes têm investigado o uso de redes neurais artificiais em diferentes domínios financeiros.

Feng et al. (2021) construíram uma DNN para alerta antecipado de riscos financeiros, utilizando uma FNN com *backpropagation*. Os resultados demonstraram que o modelo proposto foi capaz de prever com precisão as crises financeiras, apresentando uma melhoria significativa em relação aos algoritmos tradicionais. A seleção de um único tipo de empresa limita a generalização dos resultados.

Duan (2019) propôs uma MLP (*Multilayer Perceptron*) com três camadas ocultas treinada com *backpropagation*, num contexto de empréstimos P2P. O desempenho da MLP proposta é superior ao da regressão logística convencional e da MLP com apenas uma camada oculta.

Yan (2022) apresentou uma FNN com *backpropagation* para análise de fatores relevantes, estabelecendo um modelo de avaliação para a contabilidade financeira. Os resultados mostram convergência do modelo com redução do erro médio quadrático. O modelo demonstra maior precisão, confiabilidade e efetividade na contabilidade financeira, reduzindo perdas e melhorando a precisão e confiabilidade do processamento financeiro.

Aydin et al. (2022) avaliaram o desempenho dos métodos de ANN e DT (Árvores de Decisão). Concluiu-se que o modelo de ANN fornece uma taxa mais alta de classificação precisa de empresas que falham nos setores de manufatura, comércio e serviços.

Hu e Su (2022) avaliaram o risco de crédito de bancos comerciais. O desempenho de previsão de dois modelos tradicionais de previsão de risco de crédito e três modelos de ANN regularmente utilizados são comparados. A ANN tem um desempenho superior para os problemas abordados neste estudo.

Hosaka (2019) propôs um método para aplicar uma CNN (*Convolutional Neural Network*) na previsão de falências. Um conjunto de rácios financeiros é gerado aleatoriamente com base

em valores financeiros. Estes são representados como uma imagem em escala cinza, onde cada rácio financeiro corresponde a uma posição fixa. As imagens geradas são usadas como dados de treino para uma CNN. O método proposto supera métodos convencionais, como CART (*Classification and Regression Trees*), LDA (*Linear Discriminant Analysis*), SVM (*Support Vector Machine*), MLP, AdaBoost (*Adaptive Boosting*) e o Z-score de Altman.

Bem et al. (2023) criaram um modelo que prevê falência bancária, usando vários métodos para analisar os dados incluindo as ANN. Estas obtiveram um melhor desempenho que outros métodos PLS-DA (*Partial Least Squares Discriminant Analysis*), SVM e LR (Regressão Logística).

3. Descrição do problema

Neste capítulo é apresentada a empresa onde a dissertação foi feita, incluindo o sistema de subsistemas usados para análise de risco. De seguida aborda o problema de desenvolvimento de um novo subsistema de diagnóstico, assim como a solução e os objetivos.

3.1 RMP e respetivo ERM

A RMP desenvolveu uma abordagem à ERM, baseada nos princípios fundamentais do COSO (2017). Esta abordagem usa subsistemas chamados ecossistemas.

A abordagem de gestão de riscos por ecossistemas, desenvolvida pela RMP, é uma ferramenta de gestão de riscos que tem como objetivo diagnosticar, melhorar e monitorar continuamente os níveis de risco em áreas estratégicas da empresa. A RMP possui vários ecossistemas de intervenção entre os quais, o financeiro, o operacional, os fornecedores, a inovação, o mercado, a sustentabilidade, o ambiente, a *cyber security*, a rede comercial, os ativos de exploração e os clientes. Cada ecossistema considera um número de riscos diferentes, sendo que a maioria avalia entre 100 e 150 riscos.

Esta abordagem é implementada por meio de um diagnóstico de risco utilizando uma matriz especialmente desenvolvida para cada ecossistema. Com base nesse diagnóstico, é atribuído um nível de risco (*rating*) à organização, bem como um plano de melhoria e um processo de monitorização.

A conceção desta abordagem garante a conformidade com os princípios do COSO (2017), nas seguintes linhas:

- Princípio de alinhamento de objetivos e estratégia: cada ecossistema é definido e aplicado com base na compreensão do que é uma área estratégica para a organização, possuindo objetivos definidos e uma conexão com as atividades da cadeia de valor, sistemas e processos da organização.
- Abordagem integrada e transversal: as matrizes de riscos usadas em cada ecossistema são desenvolvidas levando em consideração a análise de riscos de uma determinada área estratégica dos negócios, não se restringe a um departamento ou área específica da organização. Cada matriz considera os riscos agregados que vão desde o ambiente interno e externo do negócio até às áreas de planeamento, gestão estratégica, operações, controlo de gestão e características de cada organização.
- Processo contínuo e sistemático: o diagnóstico e a atribuição do *rating* não são um fim em si mesmos, mas o princípio de um processo de intervenção, monitorização e melhoria da área estratégica em questão.

Desta forma, a metodologia atual tem a seguinte estrutura fundamental:

- Cada ecossistema é projetado para ter uma visão completa do negócio, permitindo uma análise completa dos riscos na área estratégica em questão. Cada dimensão do negócio, como ambiente externo, governança, processos de gestão, processos-chave, processos de suporte e sinais de alerta é considerada de forma integrada e abrangente como categorias de risco a serem analisadas.
- Cada uma destas categorias possui subcategorias de risco que detalham várias subáreas dentro de cada dimensão do negócio, cada uma com riscos específicos a serem analisados.
- Dentro de cada subcategoria, são identificados os riscos a serem analisados em cada ecossistema. Cada risco é avaliado numa escala predefinida de probabilidade e ocorrência, recebendo uma pontuação.

Após a avaliação de todos os riscos, é calculada uma pontuação para as subcategorias, resultando numa pontuação por categoria de risco. Utilizando um sistema de ponderação para cada categoria, é determinado o rating de risco do ecossistema em questão.

3.2 Limitações do ERM

O problema do ERM desenvolvido prende-se com o facto de que o processo seguido pela RMP é longo e as empresas precisam de fornecer muita informação sobre o seu modelo de negócio, o que gera resistência das empresas para entrar no projeto. De facto, o processo de avaliação de risco é tipicamente um processo longo e contínuo, o que acaba por desencorajar as empresas, em especial as PMEs. Usando como exemplo a empresa Moody's, uma empresa de rating, de acordo com o Neves (2017) o processo de rating dura entre 4 e 6 semanas e as suas fases podem ser verificadas na Tabela 1.

Tabela 1 - Esquema de avaliação de rating da empresa Moody's (Neves 2017)

	Dias									
	10	20	30	40	50	60	70	80	90	100
Decisão da emissão pública da dívida										
Aprovação na escolha da agência de rating										
Proposta da agência de rating										
Marcação de datas para entrevistas com gestores										
Recolha e preparação dos dados financeiros										
Apresentação dos dados										
Reunião com a agência de rating										
Notação de rating comunicada à empresa emissora										
Revisão documentação e alter. de liquidez										
Anúncio público da notação de rating										

Durante este processo de avaliação dos riscos, a recolha de dados financeiros e preparação dos dados é a fase mais demorada no projeto. Como tal o ideal seria automatizar partes do ecossistema com informações públicas. No entanto, grande parte da informação usada para o cálculo do rating de risco é confidencial e faz parte da identidade da empresa, havendo uma dificuldade em generalizar essa informação para outras empresas.

Em termos de informação pública das empresas, esta é considerada razoável quando se trata de grandes empresas, devido à publicação de relatórios anuais. No entanto, o mesmo não se verifica com a grande maioria das empresas alvo deste estudo, que são Pequenas e Médias Empresas. Em contrapartida, todas as empresas precisam de preencher a declaração IES (Informação Empresarial Simplificada) anualmente, com a informação contabilística, fiscal e estatística. Entre outras informações disponíveis na IES, inclui-se o balanço, a demonstração de resultados e os fluxos de caixa. Estes dados podem ser usados para avaliar o risco financeiro, uma vez que a partir destes podemos contruir rácios, que por sua vez podem ser usados para estimar o risco financeiro. Uma vez que esta declaração pode ser adquirida mediante um pequeno pagamento, foi considerado o ponto de partida do trabalho realizado nesta dissertação.

3.3 Solução

A solução proposta para ultrapassar as limitações do ERM atual passa por usar rácios financeiros de forma a construir um ecossistema de diagnóstico do risco financeiro. O ecossistema é construído em Microsoft Excel, para ser posteriormente integrado com os restantes ecossistemas na plataforma. Pretende-se construir um conjunto de rácios que possam ser calculados automaticamente com base em informações retiradas do IES.

A construção do ecossistema de diagnóstico requer o acesso a uma fonte alargada de dados históricos financeiros de empresas, com vista à definição dos rácios. Para tal, será usada uma base de dados a que a RMP tem acesso que contém informações sobre empresas e respetivas medidas de risco. Das medidas de risco disponibilizadas, será usada uma que combina rácios com outras informações, sendo esta medida a mais próxima do risco financeiro. Na utilização destes dados, as empresas não serão separadas por setor ou país de forma a introduzir ruído, isto é, para simular as informações desconhecidas da empresa.

Com os rácios e a medida de risco, temos um problema de regressão à qual aplicamos uma ANN, mais especificamente uma FNN com *backpropagation* para determinar a relação entre os rácios e a respetiva medida de risco. O resultado idealizado é um erro médio de 10 valores entre o valor previsto e o valor real. Dividindo a escala de 1 a 100 em intervalos de 10, teríamos que o valor previsto estaria em média na escala acima ou abaixo do valor previsto.

A utilização desta base de dados, e em concreto a utilização das medidas de risco disponíveis, pretendeu ultrapassar a inexistência atempada de dados dos testes pilotos realizados com o sistema de ERM atual. O método desenvolvido será futuramente (fora do âmbito desta dissertação) aplicado aos ecossistemas, substituindo a medida de risco pelos riscos determinados nos testes piloto.

4. Método e Resultados

Neste capítulo discutiremos o método utilizado, desde a escolha dos rácios à estrutura da ANN utilizada para a criação do ecossistema de diagnóstico. Posteriormente analisaremos os resultados do modelo desenvolvido.

4.1 Apresentação geral do método

O método consiste no uso de uma base de dados para a recolha de informações financeiras das empresas calcular rácios financeiros, e uma medida de risco.

Estes dados são depois tratados para ser analisados por uma ANN, que corresponde a um FNN com *backpropagation*.

Os hiperparâmetros da FNN são calculados com recurso ao algoritmo genético. A FNN é treinada com validação cruzada k-fold e *backpropagation*.

4.2 Base de Dados

Para efetuar esta dissertação usámos a base de dados referida no capítulo anterior, de onde foram retiramos rácios relativos a empresas da Europa, assim como dados não usados na rede neuronal, como o país da empresa e o sector, que podem ser verificados na Figura 6 e na Figura 7. Foram selecionadas 864 empresas, sendo posteriormente retiradas 12 empresas devido à presença de *outliers* com muito destaque.

Analisando a variável de risco a prever, verificámos que esta não estava balanceada, como tal removemos aleatoriamente empresas dos intervalos em excesso de forma a tornar os dados mais balanceados, resultando na distribuição presente na Figura 8. No total foram considerados dados de 19 rácios distintos, acrescentando-se a variável de risco, para um total de 604 empresas. Todos os dados são numéricos.




Figura 6 - Número de empresas por país




Figura 7 - Número de empresas por setor




Figura 8 – Distribuição da variável a prever

4.3 Escolha dos rácios

Para a escolha dos rácios a serem usados consultaram-se livros de análise financeira e outros estudos que abordam diferentes rácios (Neves 2017; Brealey et al. 2017; Higgins et al. 2009; Rist and Pizzica 2014; Zhang et al. 2023; X. Sun e Lei 2021; Feng et al. 2021; Aydin et al. 2022; Altman 1968; Wu et al. 2022; Hosaka 2019). Dos rácios recolhidos foram automaticamente excluídos aqueles aplicados a empresas cotadas em bolsa, uma vez que estes não se aplicam às PME's. Foram também retirados aqueles cuja base de dados não tinha informação para o cálculo destes, ou apenas continha informação para um reduzido número de empresas.

No total resultaram 19 rácios. Antes de os apresentar é importante ressaltar que a interpretação dos rácios pode variar de acordo com a indústria e as características específicas da empresa.

4.3.1 Rácios de Liquidez

Foram considerados 3 rácios distintos de liquidez: Liquidez Geral, Liquidez Reduzida e Liquidez Imediata, respetivamente apresentados nas equações (9) (10) e (11). Estes rácios são usados na análise financeira para avaliar a capacidade de uma empresa de cumprir as suas obrigações de curto prazo. Um valor maior geralmente indica melhor liquidez e maior capacidade de pagar dívidas no curto prazo.

$$\text{Liquidez Geral} = \frac{\text{Ativo corrente}}{\text{Passivo Corrente}} \quad (9)$$

$$\text{Liquidez Reduzida} = \frac{\text{Ativos Corrente} - \text{Inventários}}{\text{Passivo Corrente}} \quad (10)$$

$$\text{Liquidez Imediata} = \frac{\text{Caixa e Equivalentes}}{\text{Passivo Corrente}} \quad (11)$$

4.3.2 Rácios de Z-Score

O rácio de Z-Score, apresentado na equação (12), permite avaliar a eficiência com que uma empresa utiliza os seus ativos totais em relação ao seu Fundo de Maneio. Para tal, o Fundo de Maneio é dividido pelo Ativo Total. Um valor mais alto é geralmente considerado positivo, pois sugere que a maior parte dos ativos da empresa está disponível para financiar as suas operações e investimentos de longo prazo.

$$Z1 = \frac{\text{Fundo de Maneio}}{\text{Ativo Total}} \quad (12)$$

4.3.3 Rácios de Solvência

Os rácios de solvência, nas equações (13) (14) (15) e (16), são utilizados para avaliar a solvência financeira de uma empresa, ou seja, a sua capacidade de pagar as suas obrigações de forma sustentável.

A Autonomia Financeira, na equação (13), indica o grau de independência financeira da empresa em relação a terceiros. Quanto maior o valor, maior é a proporção de financiamento proveniente do capital próprio, o que é considerado positivo em termos de solvência.

$$\text{Autonomia Financeira} = \frac{\text{Capital Próprio}}{\text{Ativo Total}} \quad (13)$$

O rácio de Endividamento, na equação (14), indica o grau de endividamento da empresa em relação aos seus ativos. Um valor mais alto pode indicar maior dependência de financiamento por meio de dívidas.

$$\text{Endividamento} = \frac{\text{Passivo Total}}{\text{Ativo Total}} \quad (12)$$

O rácio de Solvabilidade, na equação (15), indica a capacidade da empresa de conseguir cumprir com as suas obrigações financeiras de longo prazo. Quanto maior o valor, maior é a capacidade da empresa de arcar com suas dívidas.

$$\text{Solvabilidade} = \frac{\text{Capital Próprio}}{\text{Passivo Total}} \quad (15)$$

Por fim, o rácio da Estrutura do Endividamento, na Equação (16), permite analisar a proporção do passivo de curto prazo em relação ao passivo total. Pode indicar o grau de dependência de financiamento de curto prazo em relação ao financiamento total.

$$\text{Estrutura do Endividamento} = \frac{\text{Passivo Corrente}}{\text{Passivo Total}} \quad (16)$$

4.3.4 Rácios de Rentabilidade

Os rácios de rentabilidade são utilizados para avaliar a rentabilidade e a eficiência operacional de uma empresa, por intermédio das Equações (17) (18) (19) (20),

O primeiro rácio de rentabilidade considerado foi a Margem Bruta (na equação (17)), que mostra a eficiência da empresa em converter as vendas em lucro bruto. Uma margem bruta mais alta indica uma maior rentabilidade operacional.

$$\text{Margem Bruta} = \frac{\text{Vendas} - \text{Custo das Vendas}}{\text{Vendas}} \quad (17)$$

O rácio de Margem Operacional, na Equação (18), indica a rentabilidade das operações principais da empresa, excluindo despesas financeiras e impostos. Uma margem operacional mais alta indica uma maior eficiência na gestão das operações da empresa.

$$\text{Margem Operacional} = \frac{\text{Resultado Operacional}}{\text{Total das Vendas}} \quad (18)$$

O rácio Margem EBITDA, na Equação (19), fornece uma visão da rentabilidade operacional, excluindo os efeitos de juros, impostos e depreciação. É útil para comparar a performance operacional entre empresas ou setores.

$$\text{Margem EBITDA} = \frac{\text{EBITDA}}{\text{Vendas}} \quad (139)$$

Por fim, o rácio de Retorno sobre os Ativos (ROA), na Equação (20), indica a capacidade da empresa de gerar lucro em relação ao investimento em ativos. Um ROA mais alto indica uma maior eficiência na utilização dos ativos para gerar lucro.

$$\text{Retorno sobre os Ativos} = \frac{\text{Resultado Operacional}}{\text{Ativo Total}} \quad (20)$$

4.3.5 Rácio de Fiscalidade

O rácio de Fiscalidade considerado foi a Taxa Efetiva de Imposto, na Equação (21), que permite avaliar a carga fiscal da empresa e a sua eficiência em termos de gestão tributária. Uma taxa efetiva de imposto mais alta indica que a empresa está a pagar uma percentagem maior dos seus lucros em impostos.

$$\text{Taxa Efectiva de Imposto} = \frac{\text{Total de Imposto Pago}}{\text{Resultado Antes dos Impostos}} \quad (21)$$

4.3.6 Rácios de Atividade

Os rácios de atividade, nas Equações (22) (23) (24), e (25) são úteis para avaliar a eficiência operacional e a gestão de ativos de uma empresa. São eles:

A Rotação dos Stocks, na Equação (22), é um indicador de velocidade da venda, e indica quantas vezes os inventários são vendidos durante um período. Uma rotação mais alta sugere uma gestão eficiente dos inventários, minimizando o excesso de stock e obsolescência.

$$\text{Rotação dos Stocks} = \frac{\text{Vendas}}{\text{Inventários}} \quad (22)$$

O rácio de Rotação dos Créditos, na Equação (23), indica quantas vezes as vendas são convertidas em recebimentos de clientes durante um período. Uma rotação mais alta indica uma cobrança mais rápida e eficiente.

$$\text{Rotação dos Créditos} = \frac{\text{Vendas}}{\text{Clientes}} \quad (23)$$

O rácio de Rotação dos Ativos Não Correntes, na Equação (24), indica quantas vezes os ativos não correntes são convertidos em vendas durante um período. Uma rotação mais alta indica uma utilização mais eficiente dos ativos de longo prazo.

$$\text{Rotação dos Ativos Não Correntes} = \frac{\text{Vendas}}{\text{Ativo Não Corrente}} \quad (24)$$

Por fim, o rácio de Rotação dos Ativos Totais, na Equação (25), indica quantas vezes os ativos totais são convertidos em vendas durante um período específico. Uma rotação mais alta é geralmente desejável, pois indica uma utilização mais eficiente dos ativos.

$$\text{Rotação dos Ativos Totais} = \frac{\text{Vendas}}{\text{Ativo Total}} \quad (25)$$

4.3.7 Rácios de Risco

Os rácios de risco apresentados nas Equações (26) e (27) são úteis para entender o impacto da estrutura de custos e financiamento de uma empresa nos seus resultados financeiros e operacionais.

O rácio de Grau de Alavanca Financeira, na Equação (26), mostra a sensibilidade do resultado antes dos impostos em relação ao resultado operacional. Um grau de alavanca financeira

maior indica que uma variação no resultado operacional terá um efeito amplificado no resultado antes dos impostos, devido a encargos financeiros, como juros sobre dívidas.

$$\text{Grau de Alavanca Financeira} = \frac{\text{Resultado Operacional}}{\text{Resultado Antes dos Impostos}} \quad (26)$$

Por sua vez, o Grau de Alavanca Operacional, na Equação (27), mostra a sensibilidade do resultado operacional em relação à margem de contribuição. A margem de contribuição é a diferença entre as vendas e os custos variáveis, representando a parte do lucro que contribui para cobrir os custos fixos e gerar lucro operacional. Um grau de alavanca operacional maior indica que uma variação na margem de contribuição terá um efeito amplificado no resultado operacional.

$$\text{Grau de Alavanca Operacional} = \frac{\text{Margem de Contribuição}}{\text{Resultado Operacional}} \quad (27)$$

4.3.8 Corelação entre as variáveis

A Figura 9 corresponde à matriz de correlação entre os riscos apresentados, cuja análise mostra que existem rácios fortemente relacionados, como a Autonomia Financeira com Endividamento, e Liquidez Geral com Liquidez Reduzida. Foi testado remover e não remover os rácios fortemente relacionados. Como os melhores resultados foram obtidos não removendo os rácios, foi tomada a decisão de manter todos os rácios na análise.




Figura 9 – Matriz de correlações

4.4 Ferramentas e Software

A ANN foi programada com recurso à linguagem Python versão 3.10.9 usando o software Jupyter Notebook versão 6.5.2. Para a construção da ANN utilizou-se várias bibliotecas disponíveis, entre as quais se destaca a biblioteca `tp.keras` da Tensorflow para a construção da ANN; a biblioteca `scikit-learn` para normalização dos valores, validação cruzada k-fold e para o cálculo das métricas de avaliação como o erro quadrático médio; a biblioteca `geneticalgorithm` para o algoritmo genético para determinação dos hiperparâmetros; e, por fim, a biblioteca `matplotlib` para desenhar gráficos.

4.5 Construção da ANN

A ANN utilizada é uma FNN treinada com *backpropagation*. Para tal definiu-se o n^o máximo de camadas ocultas, sendo este igual a 3. O número máximo de nós na 1^a camada oculta corresponde ao número de variáveis de entrada. O número máximo de nós das camadas ocultas seguintes, é igual a metade do número de nós da camada oculta anterior. Os dados de entrada foram normalizados entre 0 e 1.

Para as funções de ativação, perda e otimizador usou-se as mesmas funções mencionadas nos capítulos 2.3.2, 2.3.3 e 2.3.4 respetivamente.

Para treinar a rede neuronal utilizou-se validação cruzada *k-fold*. Como o número total de empresas é 604 e o treino será feito com um *k-fold* igual a 4, cada *fold* terá 151 amostras. Foi definido como valores possíveis para o *batch size* 151, 76 e 38. O *Batch size* é o número de amostras processadas antes do modelo ser atualizado. Imaginemos que temos 520 amostras para treinar e um *batch size* correspondente a 100. Isto significa que o algoritmo pegará em 100 amostras para treinar, após acabar pegará nas próximas 100, e no fim treinará apenas com 20 uma vez que 520 não é divisível por 100. O *batch size* máximo é igual ao número da amostra. Quanto maior for o *batch size* melhor será o treino e quanto menor for mais rápido será.

Epochs está diretamente relacionado com o *batch size*. Um *epoch* corresponde a um treino completo de todas as amostras. Se o *batch size* for igual às amostras então um *epoch* corresponde a uma iteração. Usando o exemplo anterior, um *epoch* seria equivalente a 6 iterações, isto porque é preciso treinar 6 vezes para completar um treino completo de todas as amostras. Neste caso foram definidos os valores alternativos de 50, 100 e 150. No entanto o código tem uma restrição para evitar o *overfitting* chamada *early stopping*.

A função *early stopping* é utilizada em algoritmos para interromper o treino do modelo caso não haja uma melhoria significativa no desempenho durante um determinado número de *epochs* consecutivas. Foi definido 10 para o parâmetro *patience*. Este parâmetro define o número de *epochs* que o treino pode continuar sem que haja uma melhoria na métrica monitorizada. Ou seja, o treino do modelo será interrompido se não houver uma melhoria por 10 *epochs* consecutivas.

Como previamente descrito, foi utilizado um algoritmo genético para otimizar estes hiperparâmetros da ANN. A Tabela 2 sintetiza os hiperparâmetros treinados através do algoritmo genético:

Tabela 2 - Hiperparâmetros treinados pelo algoritmo genético

Número de camadas ocultas	1 a 3
Número de Nós na 1ª camada oculta	1 a 20
Número de Nós na 2ª camada oculta	1 a 10
Número de Nós na 3ª camada oculta	1 a 5
Função de ativação	ReLU, Sigmoid, SELU e Swish
Função de perda	Erro Quadrático Médio, Erro Absoluto Médio, Huber e log-cosh
Optimizador	SGD, AdaGrad e Adam
<i>Batch size</i>	38, 76 e 151
<i>Epochs</i>	50, 100 e 150

Para saber quais seriam os melhores hiperparâmetros usou-se um algoritmo genético com os seguintes parâmetros:

- Número máximo de iterações sem melhoramento: 50, sendo esta a condição de término do algoritmo. Para chegarmos a este valor efetuamos testes em que a condição

de término era o número máximo de iterações. Foi verificado que quando a solução era melhorada o intervalo era sempre inferior a 50 iterações.

- Número máximo de iterações: 1000, esta é a condição de término usada caso a principal não ative.
- Tamanho da população: 50, isto significa que para cada iteração serão geradas 50 ANN. Começou-se com um valor pré-definido de 100, que foi posteriormente reduzido para 50 após os testes.
- Probabilidade de mutação: 10%, este valor controla a probabilidade de que cada parâmetro da ANN da solução ótima seja modificado.
- Rácio de Elites: 2%, este parâmetro garante que uma percentagem de ANN seja transmitida à próxima geração. Com o rácio de elites a 2% e a população a 50, a melhor ANN gerada é passada à próxima geração.
- Probabilidade de acasalamento: 40%, que controla a probabilidade de uma solução gerar novas ANN que contém características das 2 selecionadas. Geralmente quanto maior o valor, maior a convergência, no entanto aumenta o risco de ficar preso em mínimos locais. O valor pré-definido é de 50%.
- Porção de pais: 20%, percentagem da população da próxima geração que é preenchida com ANN da geração anterior. O valor pré-definido é de 30%.
- Tipo de acasalamento: uniforme, que controla as regras de como o acasalamento é feito. O valor pré-definido é também o uniforme.
- Função Objetivo: Minimizar o erro quadrático médio, esta penaliza mais os erros maiores em relação aos mais pequenos, já o erro absoluto médio penaliza os dois da mesma forma. Foram testadas as duas opções, sendo que o erro quadrático médio teve melhores resultados que o erro absoluto médio, embora a diferença fosse mínima. A melhoria da função objetivo com o treino pode ser observada na figura 10.




Figura 10 - Melhoria da função objetivo com o número de iterações efetuadas pelo algoritmo genético

Após terminar o algoritmo genético, o erro quadrático médio do modelo foi: 0.01883, com os seguintes hiperparâmetros selecionados pelo para a construção ANN:

- N° de camadas ocultas: 3
- N° de nós na 1ª camada: 19
- N° de nós na 2ª camada: 6
- N° de nós na 3ª camada: 3
- Função de ativação: ReLU
- Função de perda: Erro Quadrado Médio
- Optimizador: Adam
- *Batch Size*: 72
- *Epochs*: 100

4.6 Resultados

Com os hiperparâmetros selecionados pelo algoritmo genético no capítulo 4.5, criamos uma FNN com *backpropagation* e CV *k-fold*, sendo usado 4 *folds*. Na figura 11 podemos observar a perda média do treino e da validação com o número de *epochs*, para os hiperparâmetros selecionados.




Figura 11 - Perda média do treino e da validação com o número de *epochs*

O erro quadrado médio (MSE) obtido foi de: 0.01888 o que corresponde a uma raiz do erro quadrático médio de 0.1374 (RMSE) com um desvio padrão de 0,0062, considerando que o modelo está a prever valores entre 0 e 1. Para valores entre 1 e 100 temos um RMSE 13.74 (o erro médio entre o valor previsto e o valor real é 13.74) e um desvio padrão de 0.62.

4.6.1 Importância dos rácios

Foi calculada a importância através da técnica *permutation importance*, que fornece uma medida relativa de quanto cada variável contribui para o desempenho do modelo, permitindo identificar quais variáveis são mais relevantes.

- O rácio do Endividamento teve uma influência elevada.
- O rácio da Liquidez Reduzida teve uma influência moderada
- O rácio da Margem Bruta teve uma influência moderada
- O rácio do Grau de Alavanca Financeira teve uma influência moderada.
- O rácio do ROA teve uma influência moderada
- O rácio Z1 teve uma influência moderada.
- O rácio da Rotação do Ativo Total teve uma influência moderada
- O rácio da Autonomia Financeira teve uma influência moderada.
- O rácio da Liquidez Imediata teve uma influência moderada.

- O rácio do Rotação dos Ativos não Correntes teve uma influência pequena.
- O rácio da Estrutura do Endividamento teve uma influência pequena
- O rácio da Solvabilidade teve uma influência pequena
- O rácio da Margem EBITDA teve uma influência pequena
- O rácio do Grau de Alavanca Operacional teve uma influência pequena
- O rácio da Liquidez Geral teve uma influência pequena
- O rácio do Rotação dos Créditos teve uma influência pequena.
- O rácio da Taxa Efetiva de Imposto teve uma influência pequena.
- O rácio da Margem Operacional teve uma influência mínima
- O rácio da Rotação dos Stocks teve uma influência mínima.

4.7 Análise dos Resultados

A primeira validação realizada foi no sentido de determinar uma base de comparação. Nesta base de comparação, o objetivo é prever com o menor erro possível a variável que tem valores inteiros balanceados entre 1 e 100. Sem aplicar nenhum método de previsão a forma de garantir o nº mínimo de erros é dizer sempre que o resultado é 50.5, uma vez que este resultado está à mesma distância de 1 e 100. Calculando o RMSE teríamos um valor de 28.87. Concluímos que o modelo obtido é 2.1 vezes melhor que um método que utiliza sempre a mesma resposta. Usar sempre a mesma resposta parece redutor, mas um modelo que não prevê poderia ter resultados piores, isto porque utiliza-se o erro médio quadrático, que penaliza a distância.

4.7.1 Análise dos Resultados do Modelo

No âmbito desta dissertação, o objetivo era construir um ecossistema baseado em rácios, com um resultado idealizado com RMSE de 10. O resultado obtido foi de 13.74, que apesar de superior, pode ser considerado um bom resultado, tendo em conta as restrições impostas aos dados de entrada e da base de dados. Para melhorar estes resultados pode-se dividir as empresas por país e setor, uma vez que cada país tem uma economia diferente e cada setor tem características diferentes. Os rácios de entrada também podem ser melhorados e outras variáveis que não são rácios, como a receita da empresa, podem também ser incorporados.

A Figura 11 mostra que o modelo tem um pouco de *overfitting*, uma vez que a perda do treino é ligeiramente superior à perda da validação. No entanto, os resultados indicam que o modelo pode ser usado para prever dados não treinados.

4.7.2 Análise da Importância dos Rácios Financeiros

O Endividamento foi considerado o rácio mais importante no modelo, um resultado esperado uma vez que pertence aos rácios relacionados com a solvência da empresa, que já se esperava que tivesse um impacto maior nos resultados. No entanto, é de notar que a Solvabilidade e a Estrutura do Endividamento tiveram uma importância pequena. Embora o método usado *permutation importance* não dê sempre o mesmo resultado (daí a opção de não referir valores), este é consistente no nível de importância das variáveis.

Em relação aos rácios de Solvência, observamos que o modelo privilegiou os rácios que se relacionam com o valor do ativo total, nomeadamente o Endividamento e Autonomia

Financeira, sendo que estes rácios financeiros mostram a mesma informação, na medida que a soma dos dois é igual a um. Como referido anteriormente foi testado remover um deles (Capítulo 4.3), no entanto tal piorava os resultados do modelo e como tal optou-se por deixar.

A nível dos rácios de liquidez, a Liquidez Geral teve uma importância pequena, enquanto a Liquidez Reduzida e a Liquidez Imediata tiveram uma influência moderada. Estes rácios têm uma forte relação entre si, principalmente a Liquidez Geral e Reduzida, no entanto um teve uma influência moderada e outro uma influência pequena, este tipo de resultado acontece em outros estudos. De acordo com Zhang et al. (2023), o seu modelo de previsão para detetar antecipadamente as dificuldades financeiras dos 20 rácios utilizados, o rácio de liquidez geral foi o 7º mais importante e o rácio de liquidez geral o 18º mais importante.

Entre os rácios de rentabilidade temos o ROA e a Margem Bruta com importâncias moderadas, a margem do EBITDA teve uma importância pequena e a margem operacional uma importância mínima. Aqui a surpresa vai para o facto de a Margem Operacional ter uma importância mínima, uma vez que um valor mais alto deste rácio indica um risco financeiro menor para a empresa. No estudo de Zhang et al. (2023), este rácio estava em 8º.

A Taxa Efetiva de Imposto teve uma influência pequena, ao contrário do que seria de esperar, uma vez que estamos a analisar diferentes setores em diferentes países.

Nos rácios de atividade os resultados foram de acordo com o esperado. O único rácio que ficou com importância moderada foi a Rotação dos Ativos Totais. O rácio Rotação de Stocks foi considerado o pior rácio do modelo.

Nos rácios de risco tivemos novamente resultados dentro do esperado. O Grau de Alavanca Financeira tem uma importância moderada e o Grau de Alavanca Operacional uma importância pequena.

4.7.3 Comparação com outros estudos

Não podemos fazer uma comparação direta com outros estudos devido à variável distinta que está a ser prevista e à generalidade da base de dados considerada. No entanto, podemos analisar a semelhança com outros estudos dentro da área. Na análise da importância dos rácios mencionamos o estudo realizado por Zhang et al. (2023), onde é feita uma lista da importância dos rácios ordenados de 1 a 20, é importante mencionar que o método usado neste estudo é diferente assim como a lista de rácios. No entanto, entre os rácios usados no estudo e nesta dissertação existem várias semelhanças na importância dos rácios, sendo a maior diferença na Margem Operacional que ficou em 8º e nesta dissertação teve uma importância mínima.

Estudos relacionados com falências, assim como estudos que preveem antecipadamente as dificuldades financeiras, são normalmente tratados como um problema binário. Estes estudos são efetuados com dados balanceados e por isso vamos considerar o quanto a solução foi melhorada em relação à opção de acerto de um modelo aleatório que não prevê. Um modelo que não prevê teria um acerto de 50%.

Feng et al. (2021) criaram um modelo que prevê antecipadamente as dificuldades financeiras com uma precisão de 88% usando uma FNN com *backpropagation* o que equivale a uma melhoria de 4.1 vezes em relação a um modelo que não prevê. O estudo foi feito na china para um setor em específico.

Ben et al. (2023) criaram um modelo que prevê falência bancária, usando vários métodos incluindo uma ANN parecida com a que foi realizada nesta dissertação, com uma precisão de 77,34%. O melhor resultado foi obtido com outro tipo de ANN, uma FCNN (*Fuzzy Convolutional Neural Network*) com uma precisão de 78,56%, que equivale a uma melhoria de 2.32 vezes em relação a um modelo que não prevê.

Nestes casos, um modelo que não prevê e a opção de prever um valor que minimize o erro é igual uma vez que só há 2 opções, ou a empresa faliu, entrou em problemas financeiros ou não. No presente estudo, o RMSE padrão de uma escolha inteligente é 28.87, se for um modelo que retorna números aleatórios seria 40.82. Ou seja, a melhoria do modelo desta dissertação estaria entre 2.1 e 2.9 vezes. Estas comparações servem apenas para dar uma sensibilidade do valor do RMSE obtido para avaliar o modelo.

4.7.4 Limitações dos Resultados

O método utilizado usa rácios financeiros e como tal, os resultados têm algumas limitações inerentes. A mais importante é possivelmente a validade dos resultados. Como vivemos um período de instabilidade devido à guerra na Ucrânia e ainda com marcas do COVID19, os resultados podem não se manter estáveis durante muito tempo. O ideal é repetir este tipo de análise após a economia estabilizar.

Adicionalmente, o modelo não consegue captar variações nas decisões tomadas que afetam o rumo da empresa. No entanto estas decisões afetarão os rácios futuros. Novamente, para o método funcionar tem de existir um certo nível de continuidade entre o passado e o futuro.

As regras de contabilidade variam entre países e mesmo dentro do mesmo país existe espaço para manobras que influenciam os rácios, tendo influência sobre a qualidade dos dados. A informação do país poderia ajudar a ultrapassar esta limitação.

Por fim, a variável de risco utilizada não é totalmente correta na avaliação do risco, no entanto era a melhor para aproximar ao subsistema financeiro. Isto significa que o modelo obtido está inteiramente relacionado com a variável usada e não deve ser usado em circunstância alguma como a única variável na determinação do risco financeiro, podendo, no entanto, ser usado como diagnóstico.

5. Conclusões e perspectivas de trabalho futuro

5.1 Conclusão

O objetivo deste projeto foi desenvolver um subsistema para diagnosticar o risco com base em informações públicas, tendo este projeto focado no subsistema financeiro. Foi idealizado um valor médio de 10 para a diferença entre o valor previsto e o valor real, prevista pelo modelo.

Para tal, foram usados dados financeiros obtidos através de uma base de dados, de onde se retirou informação referente a 604 empresas de 10 sectores, distribuídas por 24 países. O ruído nos dados inerente desta escolha é propositado, com o objetivo de simular a informação desconhecida necessária para calcular o subsistema financeiro.

Selecionou-se 19 rácios financeiros para prever o risco e desenvolveu-se uma rede neuronal FNN treinada com *backpropagation*. Para a seleção dos hiperparâmetros, foi usado o algoritmo genético e os dados foram divididos usando validação cruzada *k-fold*.

A variável risco varia entre 1 e 100 (um valor maior indica que a empresa está menos susceptível ao risco) e o modelo desenvolvido nesta dissertação conseguiu prever o risco com um RMSE de 13.74. Embora não tenha atingindo o valor ideal, esta dissertação provou que é possível usar os rácios financeiros para diagnosticar problemas no subsistema financeiro.

Entre os 19 rácios utilizados, o rácio do Endividamento foi o rácio considerado mais importante, enquanto o da Rotação de Stocks foi considerado o menos importante.

Futuramente esperamos aplicar esta técnica não só a pilotos do subsistema financeiro como a outros subsistemas. Treinando a ANN com a informação dos testes pilotos realizados em vez da medida de risco da base de dados.

Havendo espaço para a melhoria na escolha dos rácios ou mesmo introduzir outros dados das empresas. De forma a minimizar o efeito temporal da validade dos rácios, podemos introduzir variáveis que representem a variação do rácio num período.

Aplicar o método a empresas dentro do mesmo país e de preferência dentro do mesmo setor, melhorará também os resultados.

Bibliografia

- Ahmad, Saudah, Chew Ng, and Lisa Ann McManus. 2014. "Enterprise Risk Management (ERM) Implementation: Some Empirical Evidence from Large Australian Companies." *Procedia - Social and Behavioral Sciences* 164: 541–47.
- Al-Amri, Khalid, and Yevgeniy Davydov. 2016. "Testing the Effectiveness of ERM: Evidence from Operational Losses." *Journal of Economics and Business* 87: 70–82.
- Alibrahim, Hussain, and Simone A Ludwig. 2021. "Hyperparameter Optimization: Comparing Genetic Algorithm against Grid Search and Bayesian Optimization." In *2021 IEEE Congress on Evolutionary Computation (CEC)*, 1551–59.
- Altman, Edward I. 1968. "Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy." *The Journal of Finance* 23 (4): 589–609.
- Anjum, Sanobar. 2012. "Business Bankruptcy Prediction Models: A Significant Study of the Altman's Z-Score Model." *Available at SSRN 2128475*.
- Aydin, Nezir, Nida Sahin, Muhammet Deveci, and Dragan Pamucar. 2022. "Prediction of Financial Distress of Companies with Artificial Neural Networks and Decision Trees Models." *Machine Learning with Applications* 10: 100432.
- Brealey, Richard A., Stewart C. Myers, and Franklin Allen. 2017. *Principles of Corporate Finance*. 12th Edition. New York: McGraw-Hill Education.
- Bromiley, Philip, Michael McShane, Anil Nair, and Elzotbek Rustambekov. 2015. "Enterprise Risk Management: Review, Critique, and Research Directions." *Long Range Planning* 48 (4): 265–76.
- Callahan, Carolyn, and Jared Soileau. 2017. "Does Enterprise Risk Management Enhance Operating Performance?" *Advances in Accounting* 37: 122–39.
- Choi, Rene Y, Aaron S Coyner, Jayashree Kalpathy-Cramer, Michael F Chiang, and J Peter Campbell. 2020. "Introduction to Machine Learning, Neural Networks, and Deep Learning." *Translational Vision Science & Technology* 9 (2): 14.
- Crouhy, Michel, Dan Galai, and Robert Mark. 2000. "A Comparative Analysis of Current Credit Risk Models." *Journal of Banking & Finance* 24 (1): 59–117.
- Duan, Jing. 2019. "Financial System Modeling Using Deep Neural Networks (DNNs) for Effective Risk Assessment and Prediction." *Journal of the Franklin Institute* 356 (8): 4716–31.

- Fanning, Kurt M, and Kenneth O Cogger. 1994. "A Comparative Analysis of Artificial Neural Networks Using Financial Distress Prediction." *Intelligent Systems in Accounting, Finance and Management* 3 (4): 241–52.
- Feng, Qi, Han Chen, and Ruohan Jiang. 2021. "Analysis of Early Warning of Corporate Financial Risk via Deep Learning Artificial Neural Network." *Microprocessors and Microsystems* 87: 104387.
- ISO. 2009. *ISO 31000: Risk Management: Principles and Guidelines*. International Organization for Standardization.
- Guha, Sreeparna, Rabin K Jana, and Manas K Sanyal. 2022. "Artificial Neural Network Approaches for Disaster Management: A Literature Review." *International Journal of Disaster Risk Reduction* 81: 103276.
- Higgins, Robert C, Jennifer L Koski, and Todd Mitton. 2009. "Analysis for Financial Management." McGraw-Hill Irwin.
- Hosaka, Tadaaki. 2019. "Bankruptcy Prediction Using Imaged Financial Ratios and Convolutional Neural Networks." *Expert Systems with Applications* 117: 287–99.
- Hu, Yong, and Jie Su. 2022. "Research on Credit Risk Evaluation of Commercial Banks Based on Artificial Neural Network Model." *Procedia Computer Science* 199: 1168–76.
- Jabeur, Sami Ben, and Vanessa Serret. 2023. "Bankruptcy Prediction Using Fuzzy Convolutional Neural Networks." *Research in International Business and Finance* 64: 101844.
- Jiang, Ping, and Jiejie Chen. 2016. "Displacement Prediction of Landslide Based on Generalized Regression Neural Networks with K-Fold Cross-Validation." *Neurocomputing* 198: 40–47.
- Kumar, Kaushal, Gour Sundar, and Gour Mitra Thakur. 2012. "Advanced Applications of Neural Networks and Artificial Intelligence: A Review." *IJITCS* 4 (June): 57–68.
- Kwok, Tin-Yau, and Dit-Yan Yeung. 1997. "Constructive Algorithms for Structure Learning in Feedforward Neural Networks for Regression Problems." *IEEE Transactions on Neural Networks* 8 (3): 630–45.
- Malik, Muhammad Farhan, Mahbub Zaman, and Sherrena Buckby. 2020. "Enterprise Risk Management and Firm Performance: Role of the Risk Committee." *Journal of Contemporary Accounting & Economics* 16 (1): 100178.
- McShane, Michael. 2018. "Enterprise Risk Management: History and a Design Science Proposal." *The Journal of Risk Finance* 19 (2): 137–53.
- Mohammed, Hamdu Kedir, and Adriana Knapkova. 2016. "The Impact of Total Risk Management on Company's Performance." *Procedia - Social and Behavioral Sciences* 220: 271–77.
- Neves, João Carvalho das. 2017. "Análise e Relato Financeiro—Uma Visão Integrada de Gestão." *Lisboa: Texto Editora*.
- COSO. 2017. *Enterprise Risk Management Integrating with Strategy and Performance*. Committee of Sponsoring Organizations of the Treadway Commission.
- Ojha, Varun Kumar, Ajith Abraham, and Václav Snášel. 2017. "Metaheuristic Design of Feedforward Neural Networks: A Review of Two Decades of Research." *Engineering Applications of Artificial Intelligence* 60: 97–116.

- Rasamoelina, Andrinandrasana David, Fouzia Adjailia, and Peter Sinčák. 2020. "A Review of Activation Function for Artificial Neural Network." In *2020 IEEE 18th World Symposium on Applied Machine Intelligence and Informatics (SAMI)*, 281–86.
- Rist, Michael, and Albert J Pizzica. 2014. *Financial Ratios for Executives: How to Assess Company Strength, Fix Problems, and Make Better Decisions*. Apress.
- Samek, Wojciech, Grégoire Montavon, Sebastian Lapuschkin, Christopher J Anders, and Klaus-Robert Müller. 2021. "Explaining Deep Neural Networks and Beyond: A Review of Methods and Applications." *Proceedings of the IEEE* 109 (3): 247–78.
- Sprčić, Danijela Miloš, Antonija Kožul, and Ena Pecina. 2015. "State and Perspectives of Enterprise Risk Management System Development - The Case of Croatian Companies." *Procedia Economics and Finance* 30: 768–79.
- Sun, Shiliang, Zehui Cao, Han Zhu, and Jing Zhao. 2020. "A Survey of Optimization Methods From a Machine Learning Perspective." *IEEE Transactions on Cybernetics* 50 (8): 3668–81.
- Sun, Xiaojun, and Yalin Lei. 2021. "Research on Financial Early Warning of Mining Listed Companies Based on BP Neural Network Model." *Resources Policy* 73: 102223.
- Vu, Hoang Lan, Kelvin Tsun Wai Ng, Amy Richter, and Chunjiang An. 2022. "Analysis of Input Set Characteristics and Variances on K-Fold Cross Validation for a Recurrent Neural Network Model on Waste Disposal Rate Estimation." *Journal of Environmental Management* 311: 114869.
- Wang, Qi, Yue Ma, Kun Zhao, and Yingjie Tian. 2022. "A Comprehensive Survey of Loss Functions in Machine Learning." *Annals of Data Science* 9 (2): 187–212.
- Whitaker, Richard B. 1999. "The Early Stages of Financial Distress." *Journal of Economics and Finance* 23 (2): 123–32.
- Wu, Desheng, Xiyuan Ma, and David L Olson. 2022. "Financial Distress Prediction Using Integrated Z-Score and Multilayer Perceptron Neural Networks." *Decision Support Systems* 159: 113814.
- Yan, Jiali. 2022. "Application of Improved BP Neural Network Model in Bank Financial Accounting." *Intelligent Systems with Applications* 16: 200155.
- Yun, Jiyeon. 2023. "The Effect of Enterprise Risk Management on Corporate Risk Management." *Finance Research Letters* 55: 103950.
- Zhang, Tianjiao, Weidong Zhu, Yong Wu, Zihao Wu, Chao Zhang, and Xue Hu. 2023. "An Explainable Financial Risk Early Warning Model Based on the DS-XGBoost Model." *Finance Research Letters* 56: 104045.