

**MODELOS DE PREVISÃO DE INSOLVÊNCIA DE EMPRESAS POR MEIO DE REDES NEURAIS: UM ESTUDO EMPÍRICO COM EMPRESAS DE CAPITAL ABERTO NO BRASIL**

**FRANKLIN TOMICH**  
FUNDAÇÃO DOM CABRAL

**ALEXANDRE VASCONCELOS ARONNE**  
FUNDAÇÃO DOM CABRAL

Agradecimento à órgão de fomento:  
não aplicável.

# **MODELOS DE PREVISÃO DE INSOLVÊNCIA DE EMPRESAS POR MEIO DE REDES NEURAIIS: UM ESTUDO EMPÍRICO COM EMPRESAS DE CAPITAL ABERTO NO BRASIL**

**RESUMO:** A utilização de modelos estatísticos para a previsão de insolvência desperta interesse de vários acadêmicos, analistas e usuários na análise das demonstrações contábeis, principalmente quando se busca obter uma indicação confiável de eventuais problemas financeiros futuros, dentre eles a insolvência de uma empresa. Os primeiros estudos sobre previsão de insolvência começaram na década de 30 ganhando mais impulso após a década de 60. Após estudo de vários modelos, constatou-se que estes utilizam técnicas e modelos estatísticos mais tradicionais para prever a insolvência de uma empresa empregando amostras de dados referentes apenas ao ano anterior, sendo pouco prático para tomada de decisão pelos gestores devido a necessidade de tempo hábil para se mudar as decisões e reverter um quadro desfavorável. Dessa forma, o objetivo desta pesquisa foi analisar um modelo baseado em uma técnica considerada mais recente e promissora para a previsão de insolvência de empresas, as Redes Neurais, e buscou-se validar se amostras contendo períodos anteriores seriam capazes de apresentar a mesma eficiência preditiva.

Para alcançar o objetivo, foram extraídos dados financeiros e contábeis de 200 empresas listadas na bolsa de valores brasileira, no período entre 2001 e 2021, utilizando o banco de dados da Economatica e depois de algumas filtrações e depurações, se alcançou o número final de 118 empresas sendo 51 empresas insolventes e 67 solventes para comparação dos índices.

A análise dos resultados revelou que a utilização de Rede Neural apresenta melhor resultado em comparação à Regressão Logística para a previsão de insolvência de empresas e que a utilização de indicadores contábeis combinados dos últimos dois anos anteriores ao pedido de recuperação judicial configura-se como a amostra mais expressiva para o referido modelo, constituindo assim uma relevante contribuição para a literatura acadêmica.

**Palavras-Chave:** Insolvência, Solvência, Redes Neurais, Falência, Regressão Logística.

## **INTRODUÇÃO**

Desde o começo do século, nos anos 30, deu-se início a estudos e pesquisas sobre a possibilidade da previsão de insolvência de uma empresa, onde os mesmos têm tido avanços e diversas pesquisas foram desenvolvidas dentro da área de contabilidade e finanças, todos eles buscando prever a possibilidade ou não da insolvência de uma empresa. Dentre os estudos seminais sobre o tema podemos citar Ramser e Foster (1930), Altman (1968), Deakin (1972), Blum (1974) e El Hennawy e Morris (1983). Em períodos mais atuais temos Kumar e Ravi (2007) e Ross et al. (2015), Altman, Baidya e Dias (1979), Kanitz (1976) e Elizabetsky (1976).

As pesquisas sobre insolvência destes autores, basearam-se em diferentes métodos estatísticos e diversificarão nos tipos de indicadores. Dentre estes métodos, temos por exemplo a utilização da técnica de análise discriminante com Altman (1968), da técnica matemática DEA (Análise por Envoltória de Dados - Data Envelopment Analysis) com Silva Casa Nova (2005 e 2006) e da Redes Neurais, com Lachtermacher e Epenchitt (2001).

Em geral, os modelos de previsão de insolvência adotam uma abordagem que se baseia em uma amostra contendo indicadores contábeis e financeiros referentes ao ano anterior (T-1) à ocorrência da insolvência ou à solicitação de Recuperação Judicial ou extrajudicial (RJ), com propósito de prever o estado de insolvência de uma empresa.

Esses modelos podem contribuir para a tomada de decisões na gestão corporativa, fornecendo insights valiosos sobre a saúde financeira das empresas e ajudando a mitigar riscos e impactos negativos nos interesses e investimentos de credores, gestores e investidores. No entanto, do ponto de vista dos gestores da empresa, essa abordagem pode apresentar limitações devido ao tempo limitado entre a previsão de insolvência e a tomada de decisões para reverter a situação. Ao considerar um período de análise mais abrangente, como dois ou três anos anteriores a falta de liquidez, é possível obter uma visão mais completa e antecipada dos potenciais problemas enfrentados pela empresa.

A motivação desta pesquisa foi desenvolver um modelo de insolvência que utilize redes neurais para analisar dados contábeis e financeiros dos últimos 3 anos anteriores à insolvência. Este modelo será comparado com o modelo tradicional da regressão logística e serão realizados estudos comparativos com diversas variações nos parâmetros das redes neurais até atingir a melhor performance.

## **PROBLEMA DE PESQUISA E OBJETIVO**

O presente trabalho de pesquisa visa responder à seguinte questão: As redes neurais, treinadas com série histórica de variáveis independentes, apresenta capacidade preditiva superior aos modelos tradicionais de previsão de insolvência baseados em regressão logística?

O objetivo deste estudo é desenvolver e calibrar um modelo de previsão de insolvência utilizando redes neurais, explorando diferentes configurações e parâmetros da rede. Serão utilizados diversos indicadores contábeis anuais de períodos anteriores à insolvência para treinar os modelos e avaliar o desempenho dos mesmos, para comparação dos resultados com um modelo tradicional de regressão logística.

Os objetivos específicos são utilizar a configuração do modelo de redes neurais com melhor desempenho para validar sua aplicação nos períodos de 2 anos (T-2), anteriores à insolvência e verificar se uma amostra contendo a soma dos anos (T-1) + (T-2), tem bom poder preditivo. Além disso identificar quais os indicadores mais úteis para previsão da insolvência e por fim fazer um comparativo dos resultados dos modelos das Redes Neurais com modelo de Regressão Logística utilizando a mesma amostra de dados.

Nesse contexto, é relevante investigar modelos avançados, como as Redes Neurais, para melhorar a performance preditiva e permitir uma avaliação mais assertiva do risco de insolvência por parte de tomadores de decisões, investidores, credores e empresários.

## **FUNDAMENTAÇÃO TEÓRICA**

### **Recuperação Judicial e Falência**

De acordo com Gomes (2003, p. 139), falência é o estado de direito de uma empresa, geralmente em dificuldade financeira, em que (ela não possui capacidade de realizar o pagamento de suas dívidas).

### **Insolvência e Solvência**

De acordo com os autores Ross, Westerfield e Jaffe (2015), a insolvência de uma empresa pode ser ou decorrente de fluxo, ou seja, pela falta de liquidez momentânea, ou

decorrente de saldo, devido ao valor econômico negativo, que seria o passivo a descoberto. Os autores definem a insolvência como um estado de alerta para as empresas, e as que possuem maior endividamento tendem a antecipar uma situação de insolvência.

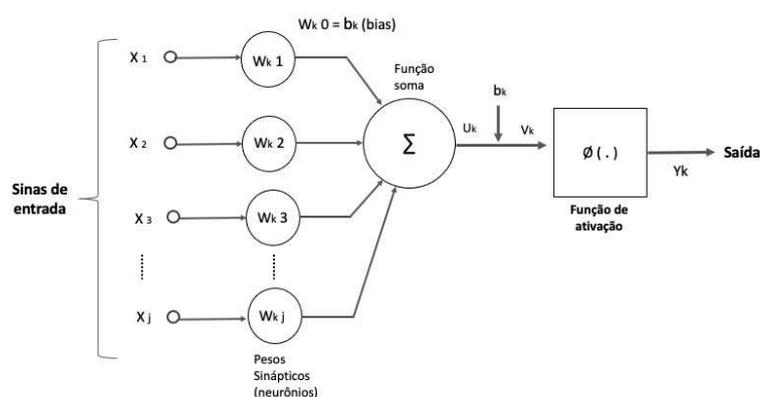
Kanitz (1978) destaca que uma empresa apresenta sintomas de que pode se tornar insolvente muito antes da sua materialização e que este processo pode ser mapeado por meio das demonstrações contábeis. Por isso, tão importante quanto definir o que caracteriza a insolvência de uma empresa, é entender qual sua causa.

Já solvência, é um termo utilizado para indicar que uma empresa está financeiramente saudável, como é descrito por Campos (2010 apud ASSAF NETO, 2010, p.267-268): "a solvência reflete sobre a capacidade da empresa em cobrir suas obrigações de prazos mais longos[...].".

## Redes Neurais - RN

As Redes Neurais são uma técnica de processamento de informação inspirada pelo sistema nervoso humano. Segundo Haykin (1999), o cérebro pode ser considerado um sistema de processamento de informação extremamente complexo, não linear e paralelo, com capacidade de organizar seus componentes estruturais - os neurônios - para realizar atividades como reconhecimento de padrões, percepção e controle motor, executando-as de maneira muito mais eficaz que sistemas computacionais. A representação de um neurônio base para o projeto de redes neurais (artificiais), segundo Haykin (2001) é apresentado na Figura 1.

Figura 1 - Modelo padrão não linear de uma Rede Neural



Fonte: Adaptado de Haykin (2001, p.38)

Pode-se observar na figura 2, três elementos básicos da Rede Neural: (1) **Um conjunto de sinapses**, cada uma caracterizada por um peso próprio. Sendo cada sinal  $X_j$  na entrada da sinapse  $j$  ligada ao neurônio  $k$  e multiplicada pelo peso sináptico  $W_{kj}$ , onde o primeiro subscrito indica o neurônio ( $k$ ) em questão e o segundo se refere ao terminal de entrada da sinapse ( $j$ ), à qual o peso se refere; (2) **Uma função soma** que realiza o somatório de todos os sinais de entrada, ponderados pelos seus respectivos pesos; (3) **Uma função de ativação** ( $\phi$  é a função de ativação do neurônio  $k$ ), para decidir acerca da transmissão do sinal (impulso) de um neurônio. Normalmente, este é escrito em intervalo unitário fechado  $[0, 1]$  ou alternativamente  $[-1, 1]$  e  $Y_k$  é o sinal de saída do neurônio.

## Regressão Logística - RL

A regressão logística é um método estatístico amplamente utilizado para modelar a

relação entre uma variável de resposta binária e um conjunto de variáveis preditoras, Cox, D. R., & Parzen, E. (1965). A função Logit é uma função logarítmica que transforma a probabilidade de sucesso em uma escala contínua, permitindo que seja modelada linearmente em relação às variáveis preditoras.

A forma geral do modelo de regressão logística é expressa pela equação 1:

$$\text{logit}(p) = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k \quad (1)$$

Onde  $\text{logit}(p)$  é o logaritmo das chances de sucesso,  $p$  é a probabilidade de sucesso,  $X_1, X_2, \dots, X_k$  são as variáveis preditoras e  $\beta_0, \beta_1, \beta_2, \dots, \beta_k$  são os coeficientes que quantificam o efeito das variáveis preditoras sobre o logit das chances de sucesso. A variável dependente ( $Y$ ) indica se a empresa é solvente ( $= 0$ ) ou insolvente ( $=1$ ) e a série de indicadores ( $X_1, X_2, \dots, X_{29}$ ) constitui o conjunto de variáveis independentes, que são os indicadores financeiros.

## METODOLOGIA

A pesquisa foi considerada de natureza empírica visto que buscou testar as hipóteses argumentadas no desenvolvimento deste trabalho e coletou e analisou dados reais de empresas de capital aberto, além de possuir a essência de investigação, baseando-se na observação (Alavi; Carlson, 1992), pois teve o objetivo principal explorar, descobrir e compreender um fenômeno ou problema específico por meio de investigação sistemática e rigorosa. Em relação à abordagem do problema, esta pesquisa se classifica como quantitativa, pois se baseia em dados numéricos e utiliza métodos estatísticos para coletar, analisar e interpretar esses dados.

A população considerada nesse estudo são as empresas brasileiras de capital aberto, não financeiras, listadas na B3 que estiveram em atividade entre os anos de 2001 e 2022 e que algum momento solicitaram a Recuperação Judicial ou extrajudicial e empresas pares em bom estado de solvência para compor amostra final que conteve 118 empresas, sendo 51 insolventes e 67 solventes. Para cada empresa insolvente foram coletadas informações contábeis dos 3 anos imediatamente anteriores ao pedido de concordata ou de recuperação judicial e para solventes, informações contábeis de 3 anos anteriores ao melhor de rentabilidade da empresa.

A seleção dos 29 indicadores embasou-se, na consideração daqueles indicadores contábeis mais utilizados em literaturas de análise de balanços e em diversos estudos sobre a previsão de insolvência, categorizados dentro de estrutura de capital e/ou alavancagem financeira, lucratividade e/ou rentabilidade e de liquidez e pode ser vista na tabela 1.

Tabela 1 – Amostra final dos indicadores utilizados no modelo.

INPUT	DESCRIÇÃO	INPUT	DESCRIÇÃO
X1	Lucro Líquido / Ativo Total (ROA)	X16	EBITDA / Endividamento Total (CP + LP)
X2	Ativo Circulante / Passivo Circulante (LG)	X17	Margem Bruta (%)
X3	Capital de Giro / Ativo Total	X18	Margem Ebit (%)
X4	EBIT / Ativo Total	X19	Estrutura de Capital (D/D+Pat Liq) %
X5	Vendas / Ativo Total (GA)	X20	Contas a Receber / Rec. Líquida (Vendas)
X6	(Ativo Circulante - Estoques) / Passivo Circulante	X21	Contas a Receber / Ativo total
X7	Dívida Total / Ativo Total	X22	Estoque / Ativo Total
X8	Ativo Circulante / Ativo Total	X23	PL / (PC + PNC)
X9	Caixa / Ativo Total	X24	Estoque / CPV
X10	Passivo Total / Ativo Total	X25	Fornecedor / Vendas
X11	Passivo Circulante / Ativo Total	X26	Dívida total / AC
X12	Fluxo de Caixa Op. / Passivo Total	X27	Fornecedor / AT
X13	Lucro Líquido / Vendas	X28	Lucro Op. / Lucro Bruto
X14	Ebit / Juros	X29	Disponível / AP
X15	Ativo Total / Pat. Líquido (GAF)		

Fonte: Elaborado pelo autor.

## Modelo da Regressão Logística (RL)

Foi conduzida uma análise comparativa entre o desempenho da Rede Neural desenvolvida e um modelo de Regressão Logística, visando assegurar uma avaliação precisa e objetiva. Para tal, foram empregadas a mesma amostra de dados, os mesmos indicadores contábeis e a mesma plataforma de análise, o software Matlab. Essa abordagem proporciona uma avaliação precisa e objetiva do desempenho de ambos os modelos na previsão de insolvência empresarial.

Como sugerido por Hair et al. (1998), a fim de obter uma boa estimativa da eficiência do modelo de previsão, é necessário dividir a amostra em duas partes: treinamento (in sample) e teste (out of sample). Neste estudo, foram utilizadas 82 observações para o conjunto de treinamento e 18 para o conjunto de teste. Destaca-se que os conjuntos de treinamento e de teste utilizados na regressão logística são os mesmos utilizados na Rede Neural (RN1), garantindo a comparabilidade dos resultados.

## Modelo de Rede Neural (RN)

Após alguns estudos de trabalhos semelhantes, verificou-se que algumas definições e a arquitetura da Rede Neural são escolhidas, na maioria das vezes, com base na experiência e conhecimento do modelador e em alguns casos, através de tentativa e erro.

Para este trabalho específico, foram testados diferentes números de neurônios e quantidade de camadas ocultas, como por exemplo [1]; [2]; [4]; [10]; [2 2]; [4 4]; [10 10] etc., até verificar o melhor índice na matriz de confusão onde obteve-se resultados dos testes com 94,4% de assertividade na configuração de 2 neurônios e 1 camada oculta, ou seja, [2].

Foram executados vários treinamentos com pontos iniciais diferentes (seed), que se refere a um número aleatório durante o treinamento ou teste do modelo. Assim foram realizados testes com o parâmetro 'rng' 2; 4; 8; 10; 100; 150; 300; 500; 1.000; 10.000; 100.000; etc.. O seed na qual o modelo apresentou a melhor performance foi 100, portanto, nas teses com diversas redes usou-se este parâmetro fixo (100), o que permitiu que os números aleatórios gerados sejam os mesmos em cada execução do modelo, tornando os resultados reproduzíveis.

Neste estudo, foi empregado os seguintes percentuais, após vários processos de tentativa e erro para apuração do melhor resultado. Treinamento: 70%; Validação: 15%; Teste: 15%.

Para definição da arquitetura no presente estudo, as configurações básicas utilizadas para a criação da Rede Neural artificial que pode ser observada na Figura 2, que disponibiliza, em termos gerais, as características da modelagem neste estudo e adotadas em trabalhos como os de Lam (2004), Minatto (2020) e McNellis (2005).

Figura 2 - Configuração final da Rede Neural

Aplicação	Classificação
Arquitetura	MLP - Multilayer Perceptron
Fluxo	Feedback
Tipo de Aprendizagem	Supervisionada
Algoritmo de treinamento	Back-propagation
Nº de dados preditores	29
Nº de camadas ocultas	1
Nº de neurônios ocultos	2
Função de ativação (camada escondida)	sigmoide (logsig)
Nº de neurônios saída	2
Função de ativação (camada de saída)	Linear
Seed	100

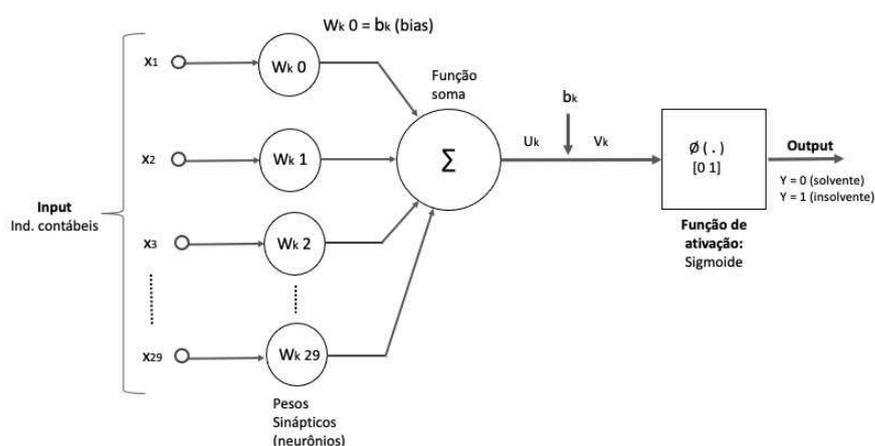
Neste modelo, para se classificar a saída em solvente ou insolvente, foi utilizada a rede do tipo perceptron de múltiplas camadas (MLP – Multi Layer Perceptron), como uma arquitetura feedforward, que seguem um fluxo para frente, a partir da camada de entrada até a camada de saída, por ser mais simples de implementar e ter maior facilidade de interpretação.

A camada de entrada conteve os preditores (indicadores contáveis) que no presente caso são as variáveis  $X_1$  a  $X_n$ , que são os indicadores financeiros escolhidos das empresas da amostra. A camada de saída contém as respostas binárias, solvente ou insolvente, referente à situação da empresa no último ano analisado. Portanto, definiu-se função de ativação como sigmoide, que mapeia os valores de saída para o intervalo entre 0 e 1.

A função de ativação utilizada foi a sigmoide (logsig – função logística sigmoide), tanto para a camada oculta, quanto para a camada de saída, tendo em consideração que, no perceptron de múltiplas camadas, devem-se utilizar funções de ativação não lineares.

Assim o diagrama de blocos final, do modelo básico utilizado para Rede Neural, pode ser visto na Figura 3, que é um modelo não-linear de um neurônio, que forma a base para o projeto de predição de insolvência de empresa, com os elementos básicos definidos como um conjunto de sinapses, cada uma caracterizada por um peso, especificamente, um sinal  $x_j$  na entrada da sinapse  $w$  conectada ao neurônio  $k$ , multiplicado pelo peso sináptico  $w_k$ . O sinal de saída ficou normalizado como intervalo unitário fechado  $[0, 1]$ .

Figura 3 - Modelo básico de Rede Neural



Fonte: Elaborado pelo autor e adaptado Haykin (2001, 2ª edição, pág. 36)

Na presente pesquisa, adotou-se a seguinte nomenclatura, Tabela 2, para designar cada modelo de rede avaliada. Essa terminologia foi adotada com o intuito de diferenciar e identificar claramente as configurações das redes neurais utilizadas no estudo.

Tabela 2 - Nomenclatura definida para as redes

Tipo de Rede	Modelo	Período da Amostra	Sigla
RL	Regressão Logística	1 ano antes do RJ	T-1
RN1	Redes Neurais	1 ano antes do RJ	T-1
RN2	Redes Neurais	2 anos antes do RJ	T-2
RN3	Redes Neurais	3 anos antes do RJ	T-3
RN12	Redes Neurais	Ano 1 + Ano 2 antes do RJ	(T-1) + (T-2)

Fonte: Elaborado pelo autor.

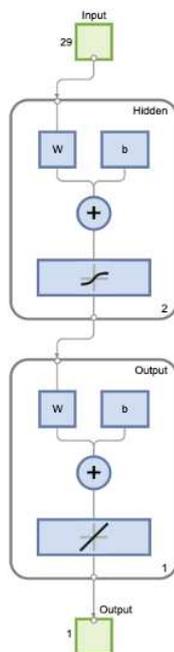
## RESULTADOS

Neste capítulo, serão expostos os resultados obtidos por meio de diferentes modelos e configurações de Redes Neurais e Regressão Logística, juntamente com uma análise comparativa entre esses modelos.

### RN1 - Resultado da Rede Neural 1

A figura 4, apresenta a Rede Neural com o fluxo escolhido, o feedforward, com o número de neurônios da camada oculta (Hidden Layer), 2, e uma saída linear com 1 neurônio.

Figura 4 - FeedForward Neural Network para RN1



Fonte: Matlab

A Figura 5, exibe os gráficos da Matriz de Confusão obtida após a aplicação da Rede Neural (RN1), e fornece o resultado da performance do algoritmo. A matriz organizou as previsões do modelo em uma tabela de duas dimensões, onde cada linha representa a classe real (Output Class) e cada coluna representa a classe prevista (Target Class). A contagem de instâncias de dados é registrada em cada célula da matriz, indicando quantas vezes o modelo classificou corretamente ou incorretamente uma determinada classe.

Para a matriz “Whole Sample”, a rede classificou corretamente 98,5% das empresas solventes e 98% das empresas insolventes apresentando um Total Geral de 98,3%, e com apenas 1 empresa classificada errada em cada uma. Foram classificadas incorretamente apenas 1,5% das solventes e 2,0 % insolventes. Para a matriz “Training”, a rede classificou corretamente 100% das empresas solventes e 100% das insolventes apresentando um Total Geral de 100% e nenhum erro de classificação.

Para a matriz final da amostra de testes “Test”, a rede classificou corretamente 90% das empresas solventes e 100% das insolventes apresentando um Total Geral de 94,4% de assertividade.

Figura 5 - Matriz de Confusão – Resultado RN1



Fonte: Matlab

Na Tabela 3, é apresentado o resultado compilado das três Matrizes de Confusão, que para a amostra de teste apenas 1 empresa foi classificada erradamente como solvente ao invés de insolvente.

Tabela 3 - Resultado compilado da matriz de confusão para modelo de RN1

	RESULTADO DA MATRIZ DE CONFUSÃO								
	Qtd. de empresas						%		
	Solventes		Insolventes		Geral		Solventes	Insolventes	Geral
<b>Whole Sample</b>	Ok	Nok	Ok	Nok	Ok	Nok	Ok	Ok	Ok
	66	1	50	1	116	2	98,5%	98,0%	98,3%
<b>Training</b>	46	0	36	0	82	0	100,0%	100,0%	100,0%
<b>Teste</b>	9	1	8	0	17	1	90%	100%	94,4%

F1 Score = 0.98039

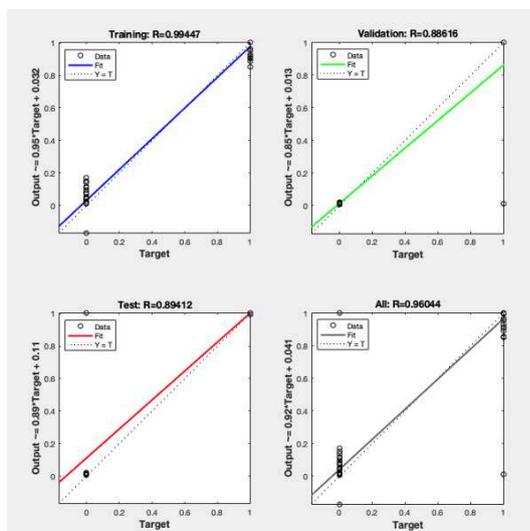
Fonte: Elaborado pelo autor

O gráfico da Figura 6, Neural Network Training Regression, exibe o desempenho da Rede Neural durante o treinamento em relação às métricas de regressão. No gráfico, há três valores de R: R de treinamento, R de validação e R de teste. Esses valores representam o coeficiente de correlação (ou coeficiente de determinação) entre as saídas previstas pela Rede Neural e os valores de destino correspondentes para os conjuntos de treinamento, validação e teste, respectivamente.

Interpretando os valores de R, na figura 10, um R de treinamento alto, no modelo 0,9947 indica que a Rede Neural foi capaz de ajustar-se muito bem aos dados de treinamento e capturar a relação entre as variáveis de entrada e a variável de saída desejada.

Um R de validação alto, no modelo 0.88616 indica que o modelo também generalizou bem para dados não vistos durante o treinamento. Já o R de teste com valor de 0.96044 pode ser considerado um valor bem alto e, portanto, um indicativo de que o modelo foi capaz de fazer previsões precisas em dados completamente novos.

Figura 6 – Gráfico Resultado - Neural Network Training Regression – RN1



Fonte: Matlab

No entanto, é importante ressaltar que o R por si só não fornece uma visão completa do desempenho do modelo. Para isto, no código desenvolvido para rodar rede, foi adicionado o “F1 Score”, que é uma métrica que combina a precisão (precision) e a taxa de verdadeiros positivos (recall) em um único valor, fornecendo uma medida geral do desempenho do modelo na identificação correta de empresas insolventes.

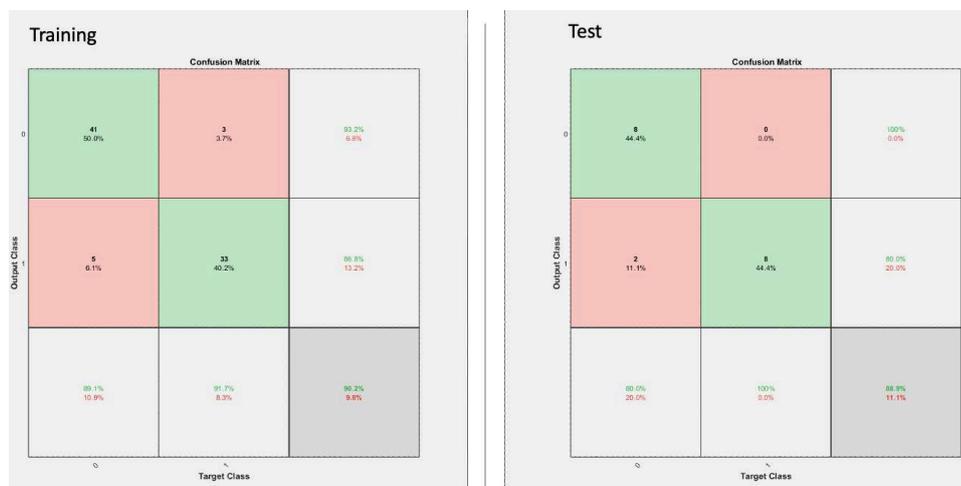
O valor obtido após várias tentativas de melhorar a performance da rede através das configurações da arquitetura foi F1 score = 98%.

O F1 score varia de 0% a 100%, onde um valor mais próximo de 100% indica um desempenho excelente na previsão de insolvência. Assim para um F1 score de 98% o modelo de Rede Neural está obtendo uma alta precisão e recall na classificação correta das empresas insolventes, minimizando tanto os falsos positivos quanto os falsos negativos.

## RL - Resultado da Regressão Logística

A regressão logística aplicada a uma amostra de dados contendo variáveis do período de 1 ano antes da insolvência apresentou uma taxa de acerto de 100% para empresas insolventes e 90% para empresas solventes na amostra de teste. Durante a fase de treinamento, os resultados indicaram uma taxa de acerto de 91,7% para empresas insolventes e 89,1% para empresas solventes, conforme Figura 7. Esses resultados destacam a capacidade do modelo de regressão logística em prever com precisão a condição de insolvência e solvência das empresas com base nas variáveis analisadas.

Figura 1 - Resultado Reg. Logística



Fonte: Matlab

### Rede Neural RN1 versus Regressão Logística

Na Tabela 4, é apresentado o resultado comparativo dos modelos para previsão de insolvência: as Redes Neurais (RN1) e a Regressão Logística (RL).

Ao analisar os resultados obtidos, foi evidenciado que a Rede Neural (RN1) apresentou uma eficácia superior em comparação ao modelo de regressão logística tanto na previsão de solvência quanto de insolvência. Esses resultados ressaltam as vantagens de utilizar redes neurais na previsão de insolvência empresarial, proporcionando maior precisão e robustez em comparação com a abordagem tradicional da regressão logística.

Tabela 1 - Análise Resultado RN vs. RL (Matriz de Confusão)

Modelo	Sigla	Training		Teste	
		Solvente	Insolvente	Solvente	Insolvente
Regressão Logística	RL	89,10%	91,70%	80%	100%
Rede Neural	RN1	100%	100%	90%	100%

Fonte: Elaborado pelo autor.

### RN2 - Resultado da Rede Neural 2

A fim de testar se o modelo com variáveis do período referentes a 2 anos anteriores ao estado de insolvência se comporta tão bem quanto a rede com 1 ano de antecedência, todo o processo de treinamento, validação e teste foi realizado novamente utilizando as mesmas amostras e mantendo a arquitetura e configurações com mesmos parâmetros. Os resultados obtidos pelo sistema são apresentados nos gráficos da Figura 8.

Figura 8 –Matriz de Confusão – Resultado RN2



Fonte: Matlab

Pelo resultado compilado da Tabela 5, verifica-se que o comportamento da RN2 foi ligeiramente inferior a RN1. Para amostra de teste as redes foram similares com capacidade de previsão de insolvência de 100% e solvência com 90%.

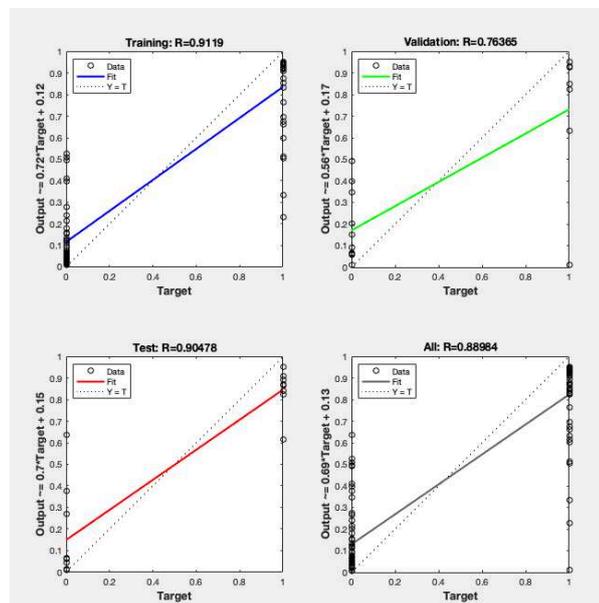
Tabela 5 - Resultado RN1 vs. RN2

Modelo	Sigla	Whole Sample		Training		Teste		F1 Score	All R
		Solvente	Insolvente	Solvente	Insolvente	Solvente	Insolvente		
Rede Neural	RN1	98,5%	98,0%	100,0%	100,0%	90,0%	100,0%	98,0%	96,4%
Rede Neural	RN2	95,5%	94,1%	95,7%	94,4%	90,0%	100,0%	94,1%	89,0%

Fonte: elaborado pelo autor

No entanto, ao avaliar o desempenho dos modelos com base no F1 Score, observou-se que o modelo RN2 apresentou um resultado de 94,1%, o que representa uma leve queda em relação ao modelo RN1, que atingiu 98%. Embora o modelo RN2 tenha apresentado um menor desempenho, avaliando isoladamente esta métrica, é importante ressaltar que ambos os modelos demonstraram um alto nível de eficácia na previsão de insolvência empresarial.

Figura 9 - Gráfico Resultado - Neural Network Training Regression – RN2



Fonte: Matlab

Ao examinar o gráfico apresentado na Figura 9, percebe-se que os valores dos três R (treinamento, validação e teste) para a RN2 são inferiores em comparação ao modelo RN1. Essa análise revela que o modelo RN2 obteve um desempenho inferior ao modelo RN1, utilizando as métricas Regressão em termos de precisão e acurácia.

Esses resultados indicam que o modelo RN1 possui um desempenho ligeiramente mais eficaz na previsão de insolvência empresarial comparado com a RN2, demonstrando uma maior capacidade de identificar corretamente as empresas em risco falta de liquidez, no contexto específico deste estudo.

## RN12 - Resultado da Rede Neural 12

Com o objetivo de avaliar o desempenho da Rede Neural ao utilizar indicadores contábeis em período de tempo mais abrangente, foi construída uma nova amostra. Nessa amostra, os 29 indicadores contábeis do período T-1 foram combinados com os 29 indicadores do período T-2, formando um conjunto de dados composto por um total de 58 indicadores.

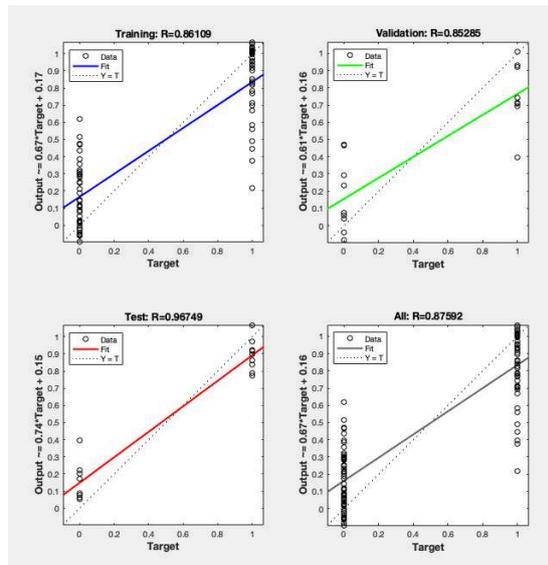
Figura 10 - Resultado Whole Sample e Training - RN12 para 15% de testes da amostra



Fonte: Matlab

Nesse novo contexto, conforme ilustrado na Figura 10, foi observada uma taxa de acerto de 100% na previsão de empresas solventes e insolventes. Além disso, o modelo apresentou um F1 Score satisfatório de 0,92929, indicando um bom desempenho na avaliação da insolvência corporativa. Para o gráfico da figura 11, observa-se um Test R = 0,967 (RN12) superior ao Test R = 0,89 (RN1) da figura 6.

Figura 11 - Gráfico Resultado - Neural Network Training Regression - RN12



Fonte: Matlab

### Análise Comparativa entre RN1 e RN12 com amostras de teste de 20% e 25%

Todos os resultados mencionados anteriormente foram obtidos utilizando uma divisão percentual das amostras, na qual 70% foram treinamento, 15% à validação e 15% aos testes.

Com o objetivo de aprofundar a investigação sobre a capacidade preditiva do modelo RN12 em comparação ao modelo RN1, que até então apresentava o melhor desempenho, foram realizadas séries adicionais de testes. Nessas novas séries, o percentual da amostra de teste foi elevado para 20% e posteriormente, em novo teste, para 25%. Essas modificações foram realizadas com o propósito de aprimorar a avaliação e garantir a robustez das conclusões obtidas.

Tabela 6 - Comparativo RN1 versus RN12 para diferentes % na amostra dos testes.

Whole Sample - Matriz de Confusão									
Conf. RN		% Solventes		% Insolventes		% Geral			
Sim.	% Testes	RN 1	RN12	RN 1	RN12	RN 1	RN12	RN 1	RN12
1	15%	98,5%	97,0%	98,0%	90,2%	98,3%	94,1%		
2	20%	98,5%	97,0%	76,5%	92,2%	89,0%	94,9%		
3	25%	92,5%	99%	86,3%	94,1%	89,8%	96,6%		

Training - Matriz de Confusão									
Conf. RN		% Solventes		% Insolventes		% Geral			
Sim.	% Testes	RN 1	RN12	RN 1	RN12	RN 1	RN12	RN 1	RN12
1	15%	100,0%	95,8%	100,0%	88,2%	100,0%	92,7%		
2	20%	100,0%	100,0%	75,0%	92,6%	88,6%	97,1%		
3	25%	97,5%	100%	88,9%	93,3%	93,4%	97,4%		

Test - Matriz de Confusão											
Conf. RN		% Solventes		% Insolventes		% Geral		F1 Score		Test R	
Sim.	% Testes	RN 1	RN12	RN 1	RN12	RN 1	RN12	RN 1	RN12	RN 1	RN12
1	15%	90,0%	100,0%	100,0%	100,0%	94,4%	100,0%	98,0%	92,9%	89,4%	96,7%
2	20%	92,9%	91,7%	70,0%	100,0%	83,3%	95,8%	85,7%	94,0%	65,6%	87,2%
3	25%	88,2%	100,0%	84,6%	93,8%	86,7%	96,7%	88,0%	96,0%	73,0%	88,8%

Fonte: elaborado pelo autor.

Notas:

- Simulação 1: Teste 15%, Treinamento 15%, Validação 70%
- Simulação 2: Teste 20%, Treinamento 20%, Validação 60%
- Simulação 3: Teste 25%, Treinamento 10%, Validação 65%

A Tabela 6 apresenta uma comparação dos resultados obtidos pelos modelos RN1 e RN12, considerando diferentes configurações de percentual de amostras de teste. Os resultados revelam um desempenho superior do modelo RN12 nas configurações avaliadas. A ampliação do conjunto de variáveis de entrada do modelo RN12 mostrou-se impactante, permitindo uma análise temporal mais abrangente e detalhada dos dados contábeis.

## Performance de Resultados por Indicador

A Tabela 7 apresenta o desempenho, na ordem decrescente, de cada um dos 29 indicadores utilizados como variáveis de entrada na Rede Neural RN1, através de uma escala de pontuação usando uma média ponderada:

Utilizando o critério de desempenho apenas para os testes de insolvência, os indicadores que apresentaram melhor desempenho foram o 1, 2, 7, 19, 61 e 62 alcançando uma taxa de acerto de 100%.

Tabela 7 - Performance Indicadores Contábeis

Descrição	Input	Teste			F1 Score	Pontuação
		Solv	Inv	Geral		
Ebit / Juros	X14	90,0%	100,0%	94,4%	86,0%	0,94
Ativo Total / Pat. Líquido (GAF)	X15	100,0%	87,5%	94,4%	78,4%	0,89
PL / (PC + PNC)	X23	100,0%	87,5%	94,4%	78,4%	0,89
Capital de Giro / Ativo Total	X3	100,0%	87,5%	94,4%	77,4%	0,89
Lucro Líquido / Ativo Total (ROA)	X1	70,0%	100,0%	83,3%	87,6%	0,89
(Atico Circulante - Estoques) / Passivo Cir.	X6	80,0%	100,0%	88,9%	72,0%	0,88
Lucro Líquido / Vendas	X13	80,0%	87,5%	83,3%	88,2%	0,85
Caixa / Ativo Total	X9	100,0%	75,0%	88,9%	77,6%	0,83
Atico Circulante / Passivo Circulante	X2	60,0%	100,0%	77,8%	74,6%	0,83
Passivo Total / Ativo Total	X10	100,0%	75,0%	88,9%	71,9%	0,82
Disponível / AP	X29	80,0%	87,5%	83,3%	69,9%	0,82
EBIT / Ativo Total	X4	80,0%	75,0%	77,8%	78,4%	0,77
Passivo Circulante / Ativo Total	X11	100,0%	62,5%	83,3%	68,1%	0,75
Margem Ebit (%)	X18	80,0%	62,5%	72,2%	76,6%	0,71
Margem Bruta (%)	X17	90,0%	50,0%	72,2%	59,7%	0,64
Fornecedor / Vendas	X25	0,0%	100,0%	44,4%	59,5%	0,62
Estoque / CPV	X24	0,0%	100,0%	44,4%	59,0%	0,62
Atico Circulante / Ativo Total	X8	70,0%	50,0%	61,1%	53,9%	0,57
Lucro Op. / Lucro Bruto	X28	100,0%	25,0%	66,7%	45,5%	0,52
Vendas / Ativo Total (GA)	X5	80,0%	25,0%	55,6%	55,6%	0,48
Fornecedor / AT	X27	100,0%	25,0%	66,7%	20,7%	0,47
Contas a Receber / Rec. Líquida (vendas)	X20	100,0%	25,0%	66,7%	20,3%	0,47
Contas a Receber / Ativo total	X21	70,0%	25,0%	50,0%	47,7%	0,43
Dívida Total / Ativo Total	X7	100,0%	0,0%	55,6%	35,3%	0,37
Fluxo de Caixa Op. / Passivo Total	X12	100,0%	0,0%	55,6%	17,8%	0,34
Estoque / Ativo Total	X22	60,0%	12,5%	38,9%	41,4%	0,33
Estrutura de Capital (D/D+Pat Liq) %	X19	100,0%	0,0%	55,6%	11,1%	0,32
Dívida total / AC	X26	100,0%	0,0%	55,6%	3,8%	0,31
EBITDA / Endividamento Total (CP + LP)	X16	100,0%	0,0%	55,6%	0,0%	0,30

Fonte: Elaborado pelo autor

Os indicadores que apresentaram as melhores performance em ambos os modelos, RN e RL, foram o X1 (Lucro Líquido / Ativo Total); X2 (Ativo Circulante / Passivo Circulante) e o X9 (Caixa / Ativo Total), sendo os dois primeiros os indicadores mais utilizados em estudos acadêmicos conforme apresentado na Tabela 4.

## CONCLUSÃO

O presente trabalho apresentou, como objetivo principal, avaliar o desempenho das Redes Neurais em diferentes configurações e compará-lo com a Regressão Logística aplicadas à problemática da previsão de insolvência de empresas de capital aberto. Para isto, foram construídos modelos com base em 2 técnicas: Regressão Logística (RL) e Redes Neurais (RN) com indicadores contábeis do ano anterior a insolvência de uma empresa. Em seguida, foi

investigado como se comportaria a performance da Rede Neural, utilizando amostra com indicadores contábeis dos últimos dois e três anos anteriores a insolvência e por fim uma amostra combinando os dois anos anteriores. Os resultados obtidos para cada modelo foram submetidos a uma análise Matriz de Confusão, Neural Network Training Regression e F1-Score.

Com base nos resultados é possível concluir que modelos de classificação constituem uma ferramenta poderosa para prever problemas financeiros, podendo auxiliar gestores e investidores na tomada de decisão, e contribuir para a redução do risco de crédito. O modelo baseado em Rede Neural para (t-1), obteve resultado superior a Regressão Logística, sendo este resultado esperado com base no que se apresenta na literatura.

Uma contribuição relevante trazida por esta pesquisa é a constatação de que, ao combinar a amostra de dados das Redes Neurais com os indicadores contábeis dos últimos dois anos anteriores à insolvência, foi obtido um desempenho superior em comparação à utilização da amostra com apenas um ano de dados. Essa descoberta ressalta a importância de considerar um horizonte temporal mais abrangente na análise de previsão de insolvência, possibilitando uma visão mais completa e antecipada dos sinais de deterioração financeira das empresas.

Este trabalho apresentou, como limitação, o tamanho reduzido da amostra, que contava com apenas 67 empresas solventes e 51 empresas insolventes. Outro ponto a ser destacado foi a ausência de algumas informações nas demonstrações contábeis, o que dificultou ou impossibilitou a construção de alguns indicadores ou de uma amostra maior e a dificuldade de validar as datas corretas das solicitações de RJ.

Para estudos futuros, sugere-se a adicionar outras variáveis explicativas, como a inclusão de dados macroeconômicos, variáveis de mercado ou características específicas das empresas. Pode-se também explorar diferentes arquiteturas de redes neurais, como redes com camadas ocultas de tamanhos variados, diferentes funções de ativação e técnicas de regularização. Isso pode ajudar a identificar a configuração mais adequada para a previsão de insolvência.

## **REFERÊNCIAS BIBLIOGRÁFICAS**

ALAVI, M.; CARLSON, P. A review of MIS research and disciplinary development. *Journal of Management Information Systems*, v. 8, n. 4, p. 45-62, 1992.

ALTMAN, Edward I. Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *The journal of finance*, v.23, n.4, p.589-609, 1968.

ALTMAN, E. I., Baidya, T. K. N.; Dias, L. M. R. Previsão de problemas financeiros em empresas. *RAE: Revista de Administração de Empresas*, v. 19, n. 1, p. 17-28, 1979.

ASSAF NETO, A. *Estrutura e Análise de Balanço: um enfoque econômico-financeiro, comércio e serviços, indústrias, bancos comerciais e múltiplos*. 9. ed. São Paulo: Atlas, 2010.

BLUM, M. Failing company discriminant analysis. *Journal of Accounting Research*, p. 1- 25, 1974.

CAMPOS, I. C. Aplicação dos modelos de Elizabetsky e Kanitz na previsão de falência: um estudo descritivo das melhores e maiores empresas do setor listadas na revista exame em 2010. In:

COX, D. R., & Parzen, E. (1965). The Analysis of Contingency Tables with Overdispersion. *Journal of the American Statistical Association*, 60(309), 548-565.

DEAKIN, E. B. A discriminant analysis of predictors of business failure. *Journal of Accounting Research*, p. 167-179, 1972.

EL HENNAWY, R.; MORRIS, R. The significance of base year in developing failure prediction models. *Journal of Business Finance & Accounting*, p. 209-223, 1983.

ELIZABETSKY, R. **Um modelo matemático para a decisão no banco comercial**. Trabalho de formatura. Departamento de Engenharia de Produção, Escola Politécnica da Universidade de São Paulo. Sa Paulo: POLI □ USP, 1976.

GOMES, Adriano. **Gerenciamento do crédito e mensuração do risco de vender**. Barueri, SP: Manole, 2003.

HAYKIN, SIMON. *Redes Neurais. Princípios e Práticas – Bookman 2ªED.*(2001)

IUDÍCIBUS, Sérgio de. *Teoria da contabilidade*. 10. ed. São Paulo: Atlas, 2010.

HAYKIN, S. *Neural networks: a comprehensive foundation*. New Jersey: Prentice Hall International, 1999.

HAYKIN, S. *Redes neurais: princípios e prática*. 2.ed. Porto Alegre: Bookman, 2001.

KANITZ, S. C. *Como prever falências*. São Paulo: Mc Graw-Hill do Brasil, 1978.

KUMAR, P. Ravi. RAVI, V., Bankruptcy prediction in banks and firms via statistical and intelligent techniques - *European Journal of Operational Research*, 180, (1), 1-28. (2007)

KANITZ, Stephen Charles. *Como prever falências*. São Paulo: McGrall-Hill do Brasil, 1978.

LACHTERMACHER, G.; ESPENCHITT, D.G. *Previsão de falência de empresas: estudo de generalização de redes neurais*, 2001, Campinas. *Anais...* São Paulo: Anpad, 2001.

Lam, M – *Neural Network techinques for financial performance prediction: integrating fundamental and techincal analysis - Decision Support Systems*, Vol 37-4 (2004).

MINATTO, FÁBIO E BORBA, JOSÉ ALONSO. *Insolvency in Brazilian Football Clubs: Proposition of Models Based on Neural Networks*. 2020

PEREIRA, S. Vinícius e Martins. F. Vidigal. *Estudos de previsão de falências – uma revisão das publicações internacionais e brasileiras de 1930 a 2015*. (2015)

PINHO, Ruy Rebello; NASCIMENTO, Amauri Mascaro. **Instituições de direito público e privado**: introdução ao estudo do direito. 16a ed., São Paulo: Atlas, 1990.

RAMSER, J. R.; FOSTER, L. O. *A Demonstration of Ratios Analysis*. **Bureau of Business Research**, University of Illinois, Bulletin n. 40, 1931

ROSS, S. A.; WESTERFIELD, R. W.; JAFFE J.; LAMB R. *Corporate finance*. 10th ed. New York: AMGH, 2015.

VALOR ECONÔMICO <https://valor.globo.com/brasil/noticia/2021/10/07/insolvncia-pode-atingir-2200-empresas-no-brasil-neste-ano-e-ganhar-fora-em-2022.ghtml>, Acesso em: 30 julho. 2022