

Received:
September 30, 2022

Accepted:
October 29, 2022

Published:
October 31, 2022

Predicting the failure of institutions based on qualitative parameters using Bayesian Networks

Joyce Ferreira da Silva¹ , Lucianne Magalhães de Oliveira¹ 

¹ Federal University of the Jequitinhonha and Mucuri Valleys, Teófilo Otoni, Brazil.

Email address

joyce.ferreira@ufvjm.edu.br (Joyce F. Silva) – Corresponding author.

lucianne.magalhaes@ufvjm.edu.br (Lucianne M. Oliveira)

Abstract

In the year 2020, the situation took dramatic contours for companies and entrepreneurs. With the COVID-19 pandemic, bankruptcy filings increased by about 12.7% compared to the previous year, and in addition, it was the first increase since the 2016 crisis. In this scenario, it is necessary to predict the bankruptcy of companies to anticipate actions and minimize the effects. The present work uses a tool known as Bayesian Networks, which is based on graph theory and probability theory to model an uncertainty scenario. The Network for the proposed study was manually modeled through the use of Netica, consequently, it was possible to obtain satisfactory results through the analysis of some sectors within the institutions. With the help of the tool, it was possible to predict the bankruptcy based on qualitative parameters of specialists, analyzing the risks that can result in the failure of organizations.

Keywords: Bayesian Networks, Bankruptcy, Netica, Organizations.

1. Introdução

A Inteligência Artificial (IA) tem como objetivo principal, transferir o comportamento inteligente para as máquinas, de forma que os programas computacionais simulem o raciocínio de especialistas, sendo esses programas capazes de fazer uma interação com o usuário, de forma amigável, resolvendo os problemas como um especialista (Nassar, 2003).

Alan Turing teve um papel fundamental no desenvolvimento da Inteligência Artificial. Ele foi o responsável pela criação do teste de Turing (Turing, 1950), projetado para fornecer uma definição operacional satisfatória de inteligência, propondo um método para verificar se máquinas são capazes de pensar. A capacidade de aprendizagem nas máquinas, um dos requisitos avaliados pelo teste, pode ser definida como a capacidade de se adaptar a novas circunstâncias, além de detectar e extrapolar padrões. Partindo desse ponto de vista, para que um sistema seja considerado inteligente, ele deve ser capaz de alcançar o melhor resultado possível, de acordo

com seu objetivo, ou quando há incerteza, o melhor resultado esperado (Russel e Norvig, 2004).

A aprendizagem de máquina mostrou ser uma área fértil de pesquisa da IA, produzindo uma série de algoritmos para a solução de problemas. Esses algoritmos variam com relação aos objetivos, à disponibilidade de dados de treinamento, às estratégias de aprendizagem e à linguagem de representação do conhecimento que eles empregam. Entretanto, todos eles aprendem através de buscas, num espaço de conceitos possíveis, para encontrar uma generalização aceitável (Luger, 2004).

As técnicas de aprendizagem têm sido bastante utilizadas na mineração de dados. A mineração de dados busca descobrir técnicas para descrever padrões estruturais em dados, como ferramenta para explicá-los e fazer previsões a partir deles. Os dados assumirão a forma de um conjunto de exemplos, como clientes que mudam sua preferência em relação a determinado produto, por exemplo. A saída terá a forma de previsões sobre esses exemplos para prever, por exemplo, se

determinado cliente alterou ou não sua preferência. A saída também pode incluir uma descrição sobre a estrutura utilizada para classificar exemplos desconhecidos e que serve para fornecer uma representação explícita do conhecimento adquirido (Witten, Frank e Hall, 2011).

De acordo com Marques (2014), a mineração de dados consiste na utilização de algoritmos no desenvolvimento de modelos e padrões para a obtenção de informações desconhecidas em grandes bases de dados. Nesta área, destaca-se a mineração de dados por meio de Redes Bayesianas, pois se trata de relacionamentos probabilísticos de variáveis de domínios em que há incerteza. Assim, podem-se encontrar modelos que representem relacionamentos de causa e efeito e, sobretudo, explorar inferências probabilísticas entre as variáveis da rede.

O método de Redes Probabilísticas introduzido por Pearl (1988) e difundido na literatura através de Redes Bayesianas, pode ser interpretado como um método de descrição e predição em mineração de dados, uma vez que se trata de uma modelagem de dependência. Esse método tem sido utilizado recentemente e de forma bem-sucedida em diversas áreas, como: estimação de risco operacional, diagnóstico médico *credit scoring*, projetos de jogos computacionais, imputação de dados, entre outros.

A partir de um determinado banco de dados, é possível gerar um espaço de estruturas. Logo após encontrar todas essas estruturas faz-se necessário “selecionar” uma delas. São empregados algoritmos de busca para esta finalidade, porém, como eles são considerados caros do ponto de vista do tempo de processamento, utilizam-se, nesse cenário, as Redes Bayesianas. Para a construção das redes, dois aspectos são correlacionados: a construção da estrutura de redes e a definição das probabilidades associadas. Na construção dessa estrutura são geradas várias redes e comparadas no final, com a finalidade de decidir qual a melhor estrutura, baseando-se em parâmetros.

Com relação às instituições, sejam elas empresariais e/ou financeiras, ambas representam um papel importante para a economia de mercado, uma vez que exercem uma função social de geração de renda, geração de empregos e movimentação da economia local. Porém, sua sobrevivência depende de diversos parâmetros, como por exemplo, análise de riscos e uma gestão

adequada, com base no capital de giro, no lucro da organização e na situação financeira.

A previsão de falência das empresas é de suma importância para as organizações. Esse assunto somente veio à tona a partir da década 70, em que ocorreu uma série de falências em grandes empresas nos EUA (Altman, 1977).

Ainda de acordo com Altman (1977), era extremamente raro encontrar uma empresa americana de grande porte sucumbindo a acontecimentos econômicos, exceto no caso de atividades fraudulentas. A partir de meados da década de 60, e especialmente no início da década de 70, o número de empresas relativamente grandes que entraram em falência nos Estados Unidos aumentou drasticamente - mesmo levando em consideração a inflação. Uma vez que a previsão de falências é de extrema importância para as instituições, considerando, por exemplo, a falência de W.T. Grant, superior a US\$ 1 bilhão no ano de 1975, qualquer modelo novo deveria ser representativo de todos os portes de empresas que pudessem vir a falir no futuro.

Perante o exposto, o principal objetivo do presente trabalho é realizar a previsão da falência de instituições com base em parâmetros qualitativos utilizando Redes Bayesianas. O estudo funcionará como uma avaliação dos principais riscos associados que podem resultar em falência, de forma a equacionar os problemas dentro das instituições permitindo assim que, posteriormente, possam ser desenvolvidas e realizadas estratégias de minimização das perdas resultantes de uma eventual falência nas organizações.

2. Técnica para modelagem

A seguir será apresentada uma pequena revisão e alguns conceitos sobre as áreas principais envolvidas no desenvolvimento deste trabalho, Redes Bayesianas, Shell Netica e alguns pontos importantes acerca da falência de instituições.

2.1. Redes Bayesianas

Uma grande barreira que se tem conhecimento para a modelagem de problemas reais é a escassez de informações completas sobre seu ambiente, condicionada a alguns fatores como imprecisão, dificuldade ou até mesmo a impossibilidade de coleta. À vista disso, uma alternativa viável é a utilização do raciocínio

probabilístico, uma vez que este se diferencia do raciocínio lógico que é utilizado pela maior parte das ferramentas computacionais.

Para Russel e Norvig (2003), a principal vantagem do raciocínio probabilístico sobre o raciocínio lógico é o fato de que agentes podem tomar decisões racionais mesmo quando não existe informação suficiente para se provar que uma ação funcionará. Com isso, as Redes Bayesianas (RBs) se configuram como uma ferramenta muito importante para modelar cenários de incerteza, uma vez que empregam a teoria de grafos e a teoria de probabilidades para modelar as relações de causa e efeito entre variáveis aleatórias. Além disso, oferecem uma estrutura intuitiva de representar o raciocínio incerto e, por isso, sua utilização apresenta uma grande vantagem no sentido de possibilitar a representação e também manipulação da incerteza baseada em princípios matemáticos fundamentados.

As Redes Bayesianas constituem um modelo gráfico que representa as relações probabilísticas entre as variáveis de um sistema. Tais redes são sempre representadas por um conjunto de vértices (V) e um conjunto de arestas. Cada vértice representa uma determinada variável aleatória e cada variável deve ter um número finito de estados, como Verdadeiro e Falso. Cada aresta representa uma relação causal entre as variáveis, sendo que a aresta é direcionada da causa para o efeito com o símbolo de uma seta (Hammond e O'Brien, 2001).

Um dos conceitos mais utilizados foi descrito por Jensen (1996), que em seu livro afirma que uma RB é a representação compacta e expressiva de relações incertas entre parâmetros em um domínio, formadas por um grafo acíclico dirigido onde os nós representam variáveis aleatórias e os arcos representam as correlações probabilísticas entre as variáveis.

Nagarajan, Scutari e Lèbre (2013) dizem que a Rede Bayesiana é um modelo gráfico que permite a representação clara e precisa das dependências probabilísticas entre variáveis aleatórias $X = X_1, X_2, \dots, X_n$ em um formato de Grafo Dirigido Acíclico (DAG) onde cada arco está associado a um par de vértices e a seus pontos finais, conforme mostra a Figura (1).

De acordo com Russell e Norvig (2004), as RBs são amplamente utilizadas no campo da Inteligência Artificial para o tratamento de incertezas e apoio às tomadas de decisão

sistêmicas. A aplicação de RBs atribuiu um grau de crença entre 0 e 1 a cada possibilidade, permitindo que os agentes lidem com um alto grau de incerteza, analisando as evidências das probabilidades, possibilitando realizar diversos tipos de consultas.

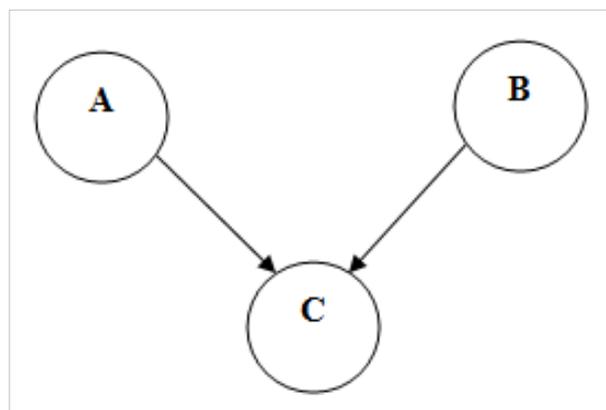


Figura 1 – Grafo bayesiano das relações condicionais entre variáveis.

Com a Rede Bayesiana construída e conhecendo-se os relacionamentos entre os nós, é possível realizar a inferência bayesiana que computa a probabilidade dos resultados dadas algumas entradas. A inferência bayesiana, que é um tipo de inferência probabilística, pode ser utilizada para os propósitos de diagnóstico (verifica os efeitos para as causas), causal (observa as causas sobre as evidências), inter-causal (analisa causas que têm um efeito em comum) e mista (combina dois ou mais tipos de propósitos) (Fernandes, Zapelini e Comuello, 2012).

A fórmula (1) representa o Teorema de Bayes, que apoia a inferência bayesiana.

$$P(B|e) = \frac{P(e|B)P(B)}{P(e)} \quad (1)$$

Na fórmula descrita, podemos pensar o evento e como sendo uma evidência associada a um nó de entrada. A ocorrência dessa evidência acarreta uma mudança na probabilidade $P(B)$, que é a probabilidade à priori do evento B ocorrer. Com isso, temos que $P(B|e)$ será a probabilidade do evento B ocorrer, dado que foi observada a evidência e. O termo $P(e)$ é um fator de normalização e $P(e|B)$ é a probabilidade de e ocorrer dado B. À vista disso, é possível calcular quais são as chances de um determinado evento ocorrer.

Dessa forma, os métodos bayesianos possibilitam representar numericamente o grau de certeza sobre condições de incerteza, e manipulá-lo de acordo com as regras definidas na teoria da probabilidade, pois a teoria bayesiana está fundamentada nesta teoria (Heckerman, 1995).

2.1.1. Shell Netica

A Rede Bayesiana a ser implementada neste trabalho faz a utilização do Shell Netica para Sistemas Específicos Probabilísticos. Este é um software comercial que foi desenvolvido pela empresa Norsys Software [https://www.norsys.com/netica.html], tendo como foco principal o trabalho com Redes Bayesianas. Ele foi projetado com o objetivo de ser simples para o usuário, confiável e com alto grau de desempenho, sendo essa a ferramenta selecionada por muitas das principais empresas e agências governamentais do mundo.

O Netica faz uso das Redes Bayesianas para realizar inferências utilizando algoritmos e apresenta um ótimo desempenho e facilidade de implementação. A partir da escolha do estudo que se deseja realizar, o usuário utiliza o Shell para informar as determinadas condições ou atributos em cada nó da rede construída, que possui uma probabilidade a priori e a posteriori e também relação com os outros nós presentes na rede. A cada atributo inserido como entrada em um nó, o Netica realiza o cálculo das probabilidades dos nós a eles associados, calculando a probabilidade final.

O Shell Netica é considerado de fácil manuseio, pois possui uma interface gráfica interativa, onde cria os nós da RB que dizem respeito às variáveis do problema, define as respectivas ligações entre esses nós que são as dependências causais entre as variáveis e, finalmente, atribui probabilidades condicionais a priori para cada nó.

2.2. Falência de instituições

No Brasil e no mundo são enfrentadas grandes crises econômicas e também oscilações financeiras, como por exemplo, a grande depressão que ocorreu no ano de 1929, a crise financeira em 2008, a crise da dívida na Europa no ano de 2009 e a crise da COVID-19 em 2020, o que fez com que a previsão de falência das empresas se configurasse como uma questão ainda mais

importante. Fatores que se tornaram de grande interesse e importância por parte das instituições são os estudos e pesquisas mais abrangentes e assertivos em relação à saúde financeira das mesmas, tendo como objetivo ajustar de forma mais adequada o apetite de risco e adaptar as possíveis ofertas a capacidade de pagamento real das empresas.

Mário e Aquino (2004) expõem sobre o fenômeno da falência, e sobre a possibilidade de dividi-lo em dois momentos: um que se configura pela operação normal da empresa, e outro que se inicia com a sua insolvência até a entrada no processo de falência. O primeiro momento é o objeto de estudos, especificamente, dos modelos de previsão de falência, em que se busca identificar, com antecedência, se uma empresa entrará em insolvência e conseqüente falência (nível de probabilidade). Este processo serve, principalmente, para fins de análise de concessão de crédito (Mário, 2002). O outro vai do momento da entrada em estado de insolvência até a decretação da falência e sua condução, abarcando todo o procedimento processual (Hart, 2000).

Schumpeter apud Altman, Baidya e Dias (1979), afirmam ser a falência um acontecimento normal, podendo ter efeito purificador na sociedade e na economia. Considerando-se, em especial, as situações de incapacidade empresarial ou as de crise falimentar, segundo a visão de alguns juizes, tem a falência, também, um efeito pedagógico (Mário, 2002), ao apresentar à sociedade erros cometidos pelas gestões empresariais inadequadas.

Os estudos iniciais sobre previsão de falência das empresas começaram a ser publicados em meados da década de 30 com foco na análise univariada e perduraram até a década de 60 (Beaver, 1966). A partir de então, modelos mais robustos passaram a ser testados e o mais conhecido deles foi o Z-Score que utiliza análise discriminante multivariada (Altman, 1968). Nos anos 80, novos estudos passaram a avaliar a probabilidade de falência através de modelos de regressão Logit (Ohlson, 1980) e Probit (Zmijewski, 1984 e Shumway, 2001). Apesar disso, novos estudos já mostram que a utilização de Inteligência Artificial para prever a falência das empresas tem apresentado taxa de precisão acima das demais técnicas (Kumar e Ravi, 2007; Rafiei, Manzari e Bostanian, 2011).

Para Meirelles et al. (2000), a crença de que apenas “boas ideias” seriam suficientes para assegurar o sucesso e a sobrevivência de uma organização não vem demonstrando ser verdadeira por alguns motivos. Primeiro, devido às falhas nas previsões em que se apoiam os executivos e nas quais suas ideias se baseiam, e segundo, pelo fato de as mudanças ambientais serem tantas que os procedimentos estruturados se revelam insuficientes para adequar a organização à nova realidade. Assim, uma organização, em função de seus valores, sua cultura, sua capacidade financeira e seus objetivos, deve encontrar o melhor modelo de formulação e implementação das estratégias que fornecerão a base para seu sucesso ou insucesso.

É certo que a falência de qualquer empresa não é algo que se possa prever com facilidade. Caso contrário, estaríamos falando de uma de duas situações: não resultaria a efetiva falência da empresa, uma vez que seriam tomadas as devidas providências para que tal não acontecesse ou, pelo contrário, seria uma “profecia auto-cumprida”, porque os fornecedores e os bancos cortariam o crédito e os clientes perderiam a confiança (Robinson, 1995). Ainda assim, é possível verificarmos que uma empresa não sofre um declínio ou um colapso, sem que antes existam sinais que o indiquem. Tentativas de se realizar a previsão de falência são muito importantes para os investidores, credores e também para os clientes.

No que diz respeito aos investidores e aos credores é de fácil compreensão que em uma situação de decretação de falência, estes só teriam e perder. Por outro lado, embora os efeitos da falência não sejam identificados facilmente e diretamente em relação aos clientes, eles podem vir a sofrer os impactos dessa ocorrência.

3. Metodologia

No presente trabalho, as Redes Bayesianas foram criadas manualmente através da utilização do software Netica (versão gratuita e limitada), que possibilitou a criação dos nós e dos arcos considerando as informações obtidas a partir de uma base de dados contendo 250 instâncias. Os dados utilizados são reais e foram obtidos a partir de um dos maiores bancos comerciais da Coreia, onde foram realizadas análises de empresas do ramo de manufatura e serviços. Este conjunto de dados pode ser encontrado na página da UCI Machine Learning Repository – Centro de

Aprendizado de Máquina e Sistemas Inteligentes [https://archive.ics.uci.edu/ml/index.php], que possui cerca de 600 conjuntos de dados com acesso gratuito. O conjunto de dados foi doado a UCI no dia 9 de fevereiro de 2014. Este repositório de aprendizado de máquina consiste de um acervo que é amplamente utilizado pelas pessoas que trabalham na área de machine learning (para realizar uma análise empírica de algoritmos de aprendizado de máquina) e também por educadores, estudantes e pesquisadores em todo o mundo. O acervo teve um grande impacto na sociedade devido a sua importância para a ciência da computação, tendo sido citado milhares de vezes.

A formatação da base de dados foi necessária para que seus atributos pudessem ser lidos pelo Netica. Dessa forma, a base de dados foi convertida de seu formato original (.rar) para o formato de texto (.txt), onde as variáveis de interesse e seus atributos associados foram separados por tabulação, conforme podemos verificar na Figura (2).

	RiscoIndustrial	RiscoGestao	FlexibilidadeFinanceira	credibilidade	Competitividade	RiscoOperacional	Situacao
Positivo	Positivo	Medio	Medio	Positivo	Naofalencia	Naofalencia	
Negativo	Negativo	Medio	Medio	Negativo	Naofalencia	Naofalencia	
Medio	Medio	Medio	Medio	Naofalencia	Positivo	Naofalencia	
Positivo	Positivo	Negativo	Positivo	Positivo	Negativo	Naofalencia	
Negativo	Medio	Positivo	Medio	Positivo	Naofalencia	Naofalencia	
Positivo	Positivo	Medio	Positivo	Medio	Naofalencia	Naofalencia	
Positivo	Positivo	Medio	Positivo	Medio	Naofalencia	Naofalencia	
Positivo	Positivo	Medio	Positivo	Medio	Naofalencia	Naofalencia	
Positivo	Positivo	Medio	Positivo	Medio	Naofalencia	Naofalencia	
Negativo	Negativo	Medio	Positivo	Medio	Negativo	Naofalencia	
Negativo	Negativo	Medio	Positivo	Medio	Negativo	Naofalencia	
Negativo	Negativo	Medio	Positivo	Medio	Negativo	Naofalencia	
Negativo	Negativo	Medio	Positivo	Medio	Negativo	Naofalencia	
Negativo	Negativo	Medio	Positivo	Medio	Negativo	Naofalencia	
Negativo	Negativo	Medio	Positivo	Medio	Negativo	Naofalencia	
Medio	Medio	Medio	Positivo	Medio	Naofalencia	Naofalencia	
Medio	Medio	Medio	Positivo	Medio	Naofalencia	Naofalencia	
Medio	Medio	Medio	Positivo	Medio	Naofalencia	Naofalencia	
Positivo	Negativo	Medio	Medio	Positivo	Naofalencia	Naofalencia	
Positivo	Negativo	Medio	Medio	Negativo	Naofalencia	Naofalencia	
Positivo	Positivo	Medio	Medio	Positivo	Positivo	Naofalencia	
Negativo	Positivo	Positivo	Positivo	Positivo	Negativo	Naofalencia	
Negativo	Positivo	Positivo	Positivo	Positivo	Negativo	Naofalencia	
Negativo	Negativo	Medio	Positivo	Positivo	Medio	Naofalencia	
Negativo	Negativo	Medio	Positivo	Positivo	Medio	Naofalencia	
Medio	Negativo	Medio	Positivo	Medio	Medio	Naofalencia	
Medio	Negativo	Medio	Positivo	Medio	Negativo	Naofalencia	
Medio	Negativo	Medio	Positivo	Medio	Negativo	Naofalencia	
Medio	Positivo	Negativo	Positivo	Positivo	Positivo	Naofalencia	
Medio	Positivo	Negativo	Positivo	Positivo	Positivo	Naofalencia	
Medio	Positivo	Negativo	Positivo	Positivo	Negativo	Naofalencia	
Medio	Negativo	Negativo	Medio	Positivo	Positivo	Naofalencia	

Figura 2 – Representação parcial da base de dados utilizada.

A Rede Bayesiana construída visa realizar a previsão do cenário de falência de instituições a partir de dados qualitativos de especialistas, sendo esta composta por 7 nós. Um representa a respectiva “Situação” das instituições e seus atributos “Falencia” e “NaoFalencia”, enquanto os demais representam as variáveis consideráveis para se definir essa situação, são elas: “RiscoIndustrial”, “RiscoGestao”, “FlexibilidadeFinanceira”, “Credibilidade”, “Competitividade” e “RiscoOperacional”, cada um desses fatores de risco com os níveis “Positivo”, “Medio” e “Negativo”.

Uma vez que temos descrita a parte qualitativa da rede representada no modelo, pode-se construir a parte quantitativa determinando-se as probabilidades condicionais à priori para cada variável, conforme podemos verificar na Figura (3). Essas probabilidades foram obtidas a partir da leitura da base de dados pelo Netica. A etapa que consiste em determinar as partes qualitativa e quantitativa da rede integram a fase de Aquisição de Conhecimento de um Sistema Especialista.

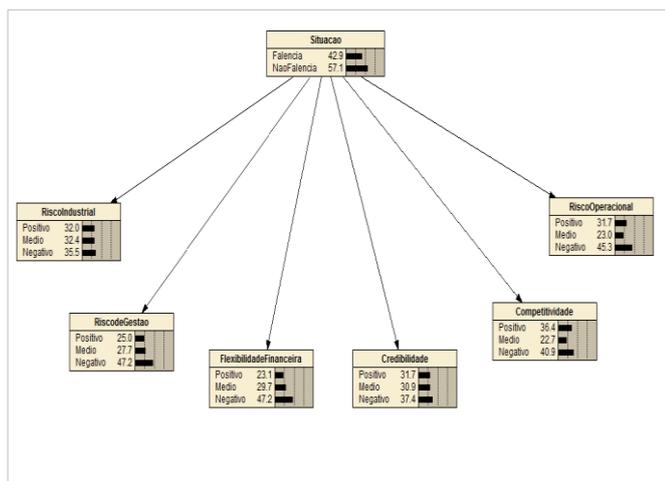


Figura 3 – Rede bayesiana com as probabilidades à priori associadas às variáveis.

Por conseguinte, o raciocínio realizado pelo sistema deverá considerar as probabilidades a priori, ou seja, não condicionais obtidas para que, a partir dos dados das variáveis consideráveis do problema, o sistema possa calcular as probabilidades a posteriori.

4. Resultados e discussões

Após a construção da Rede Bayesiana no Netica e a inserção dos valores estatísticos para cada nó, foram realizados alguns testes com a finalidade de verificar o desempenho e a eficiência do sistema.

Ao realizarmos a primeira inferência na rede e selecionarmos os atributos “RiscoIndustrial” = “Positivo”; “RiscoGestao” = “Negativo”; “FlexibilidadeFinanceira” = “Medio”; “Credibilidade” = “Medio”; “Competitividade” = “Medio” e “RiscoOperacional” = “Positivo” é possível verificar que, dados os atributos selecionados para cada variável, obtemos que a “Situacao” final para as instituições será de “NaoFalencia”, com uma respectiva porcentagem de 99,8%, conforme pode-se verificar na Figura (4).

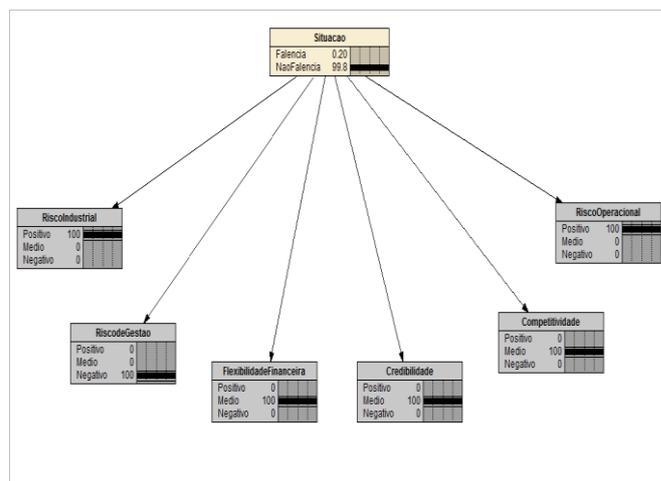


Figura 4 – Inferência 1.

Dessa forma, é possível identificar que apenas o “RiscoGestao” possui “Negativo” como atributo, ou seja, a gestão está operando negativamente, já as demais variáveis são classificadas como “Positivo” e “Medio”, o que faz com que as instituições detenham de uma probabilidade mínima de 0,2% de situação de falência.

Por outro lado, no segundo caso, descrito na Figura (5), ao realizarmos uma nova inferência na rede verificamos que as instituições possuem uma possibilidade de 51,9% de chance de decretar falência, visto que somente a área financeira e a operacional operam de forma positiva, já a gestão e a credibilidade da instituição possuem “Medio” como atributo. Por fim, com relação a situação industrial e a competitividade no mercado, ambas estão caracterizadas negativamente, resultando na “Situacao” final para este cenário.

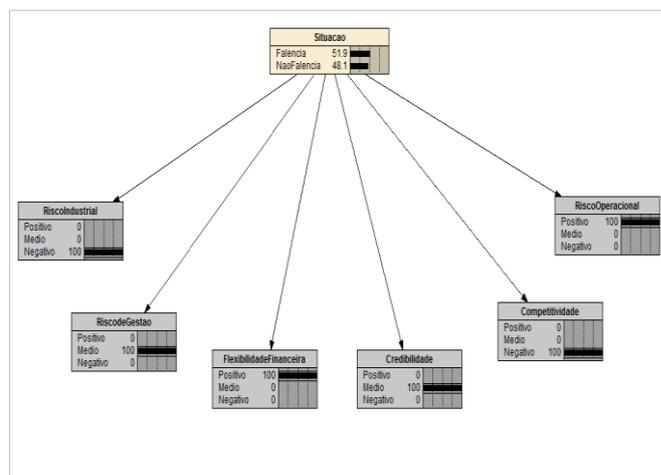


Figura 5 – Inferência 2.

Na Figura (6), podemos observar que há uma probabilidade de 100% das instituições decretarem falência, uma vez que apenas a área operacional

apresenta um desenvolvimento “Positivo”. Em contrapartida, todas as demais variáveis analisadas possuem “Negativo” como atributo, o que indica que, embora as instituições detenham de pontos e processos positivos com relação ao seu setor operacional, isso não é um requisito suficiente para considerar que não seja decretada a situação de falência.

A seguir, temos uma quarta inferência realizada na rede, conforme demonstrado na Figura (7). Podemos verificar que as instituições possuem certa estabilidade nos setores industrial, de gestão, financeiro e operacional, o que resulta em uma porcentagem consideravelmente alta de 76,1% de chance de não decretar estado de falência. Por outro lado, a variável “Competitividade” apresenta como atributo “Negativo” o que influencia em uma taxa de 23,9% de chance de falência. Posto isso, não seria viável para a empresa que todas as áreas se mantivessem em uma situação de estabilidade, representada pelo atributo “Medio”, uma vez que, tendo a credibilidade como único ponto “Positivo” das instituições, caso essa credibilidade fosse mediana, por exemplo, as chances de a empresa ter que vir a decretar falência seriam maiores frente a esse cenário.

Por fim, ao realizarmos uma última inferência na rede (Figura 8), selecionamos o atributo “Falencia” para a situação das instituições. Com isso, é possível identificar que dentre todas as variáveis consideráveis as que mais influenciam para o cenário de falência são, em ordem decrescente, a “Competitividade” com um percentual de 94,5%, a “FlexibilidadeFinanceira” com 93,6% e a “Credibilidade” com uma probabilidade de 80,0%.

5. Considerações finais

No presente trabalho buscou-se estruturar uma Rede Bayesiana que modelasse o cenário de incerteza a cerca da falência de instituições, tendo como base alguns parâmetros qualitativos. Assim sendo, a modelagem bayesiana, juntamente com o software Netica, mostrou-se muito interessante para esta abordagem, uma vez que possibilitou a obtenção de resultados satisfatórios e eficientes para o estudo proposto. A eficiência da rede se deu, principalmente, pela capacidade probabilística que as RBs detêm ao fazerem uso de um conjunto de dados já existente para deduzir resultados prováveis.

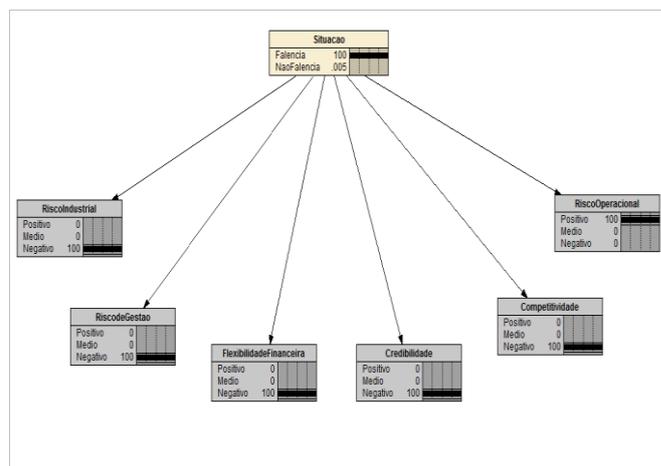


Figura 6 – Inferência 3.

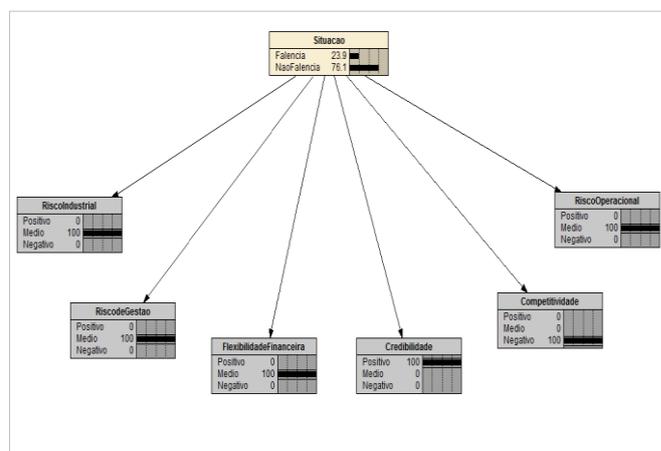


Figura 7 – Inferência 4.

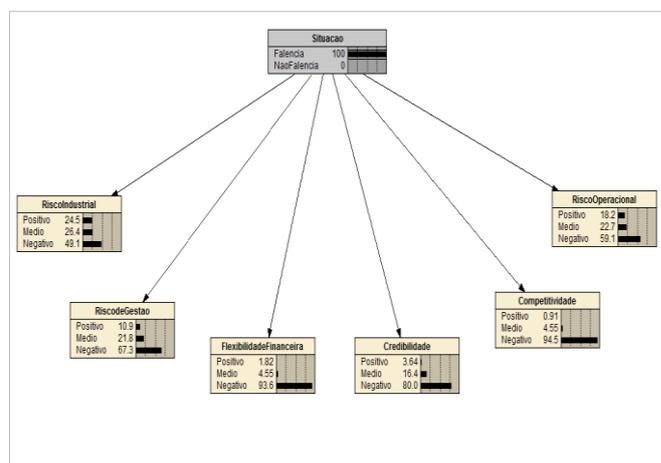


Figura 8 – Inferência 5.

No decorrer da realização dos cenários de teste (descritos pelas Figuras 4, 5, 6, 7 e 8) foi possível identificarmos que a Rede Bayesiana proposta obteve sucesso ao identificar se, baseado em alguns atributos das variáveis, as instituições podem vir ou não a decretar falência e quais os graus de probabilidade associados a essas ocorrências. A análise dos atributos relacionados aos setores industrial, operacional, de gestão,

financeiro e a credibilidade e competitividade foi capaz de fornecer resultados pertinentes para identificação da possível situação das instituições frente às mudanças nesses setores.

Propõe-se como trabalhos futuros, aprofundar as pesquisas no ambiente dos negócios para verificar quais fatores, além dos mencionados, podem vir a influenciar no cenário de falência ou não falência das instituições. Seria interessante também, o aprimoramento e aumento da estrutura da Rede Bayesiana construída, incluindo novas variáveis que, após as pesquisas, forem consideradas apropriadas para uma melhor análise de forma a se obter mais informações e enriquecer o trabalho.

Referências

- Altman, E.I., 1968. *Financial ratios, discriminant analysis and the prediction of corporate bankruptcy*. The Journal of Finance, 23(4), pp. 589-609. <https://doi.org/10.2307/2978933>
- Altman, E.I., 1977. *O Modelo Z de Falência - Uma Análise Retrospectiva e Prospectiva*. Revista Brasileira de Mercados de Capitais. Rio de Janeiro, pp. 401-431.
- Altman, E.I., Baidya, K.N. and Dias, L.M.R., 1979. *Previsão de problemas financeiros em empresas*. Revista de Administração de Empresas, 19(1), pp. 17-28. <https://doi.org/10.1590/S0034-75901979000100002>
- Beaver, W.H., 1966. *Financial ratios as predictors of failure*. Journal of Accounting Research, 4(3), pp. 71-111. <https://doi.org/10.2307/2490171>
- Dua, D. and Graff, C., 2019. *UCI Machine Learning Repository*. Irvine, CA: University of California, School of Information and Computer Science. Disponível em: <<http://archive.ics.uci.edu/ml>> [Acessado 1 agosto 2022].
- Fernandes, A.M.R., Zapelini, C. e Comuello, E., 2012. Rede Bayesiana para Detecção da Intensidade da Dor. In: *Simpósio de Excelência em Gestão e Tecnologia, Tecnologia da Educação*.
- Hammond, T.R. and O'Brien, C.M., 2001. *An application of the Bayesian approach to stock assessment model uncertainty*. ICES Journal of Marine Science. Oxford University Press, 58(3), pp. 648–656. <https://doi.org/10.1006/jmsc.2001.1051>
- Hart, O., 2000. *Different approaches to bankruptcy*. Discussion paper 1903, Harvard Institute of Economic Research, in Social Science Research Network. Disponível em: <https://papers.ssrn.com/paper.taf?abstract_id=241066> [Acessado 2 agosto 2022].
- Heckerman, D., 1995. *A bayesian approach to Learning Causal*. Technical Report Msr-Tr-95-04. Microsoft Research. Disponível em: <<https://www.microsoft.com/en-us/research/publication/a-bayesian-approach-to-learning-causal-networks/>> [Acessado 2 de agosto 2022].
- Jensen, F.V., 1996. *An introduction to Bayesian networks*. [S.l.]: UCL press London. v.210.
- Kumar, P.R. and Ravi, V., 2007. *Bankruptcy prediction in banks and firms via statistical and intelligent techniques—A review*. European Journal of Operational Research, 180(1), pp. 1-28.
- Luger, G.F., 2004. *Inteligência Artificial: Estruturas e estratégias para a solução de problemas complexos*. 4th ed. Porto Alegre: Bookman.
- Marques, A.F., 2014. *Aplicação de clusterização de dados na base de dados do zoneamento ecológico-econômico de Minas Gerais*. 88p. Monografia (Bacharelado em Sistemas da Informação) - Universidade Federal de Lavras, MG.
- Mário, P.C., 2002. *Contribuição ao estudo da solvência empresarial: uma análise de modelos de previsão – estudo exploratório aplicado em empresas mineiras*. São Paulo. Dissertação (Mestrado em Controladoria e Contabilidade). FEA – USP.
- Mário, P.C. e Aquino, A.C.B., 2004. Falências. In Iudicibus, S. e Lopes, A.B. *Teoria avançada da contabilidade*. São Paulo: Atlas, pp. 186-232.
- Meirelles, A.M, Gonçalves, C.A., e Almeida A.F., 2000. Uma abordagem para estratégia utilizando analogias. In: *Encontro Nacional da Associação de*

- Pós-graduação em Administração. Florianópolis. Anais Florianópolis: ANPAD.
- Nagarajan, R., Scutari, M. and Lèbre, S., 2013. *Bayesian networks in R*. Springer, v.122, pp. 125–127.
- Nassar, S.M., 2003. *Sistemas Especialistas Probabilísticos - Notas de Aula*. 69p. In: Curso de Pós-Graduação em Ciência da Computação, UFSC.
- Ohlson, J.A., 1980. *Financial Ratios and the Probabilistic Prediction of Bankruptcy*. Journal of Accounting Research, 18(1), p.109-131.
<https://doi.org/10.2307/2490395>
- Pearl, J., 1988. *Probabilistic Reasoning in Intelligent Systems*. Morgan Kaufmann, San Mateo, CA.
- Rafiei, F.M., Manzari, S.M. and Bostanian, S., 2011. *Financial health prediction models using artificial neural networks, genetic algorithm and multivariate discriminant analysis: Iranian evidence*. Expert Systems with Applications, 38(8), pp. 10210-10217.
<https://doi.org/10.1016/j.eswa.2011.02.082>
- Robinson, S., 1995. *Manual de Gestão Financeira*. Edições CETOP, Mem Martins.
- Russel, S. and Norvig, P., 2003. *Artificial Intelligence a Modern Approach*. 2nd ed. Upper Saddle River, New Jersey: Prentice Hall.
- Russel, S. e Norvig, P., 2004. *Inteligência Artificial*. 2nd ed. Rio de Janeiro: Elsevier.
- Shumway, T., 2001. *Forecasting bankruptcy more accurately: A simple hazard model*. The Journal of Business, 74(1), pp. 101-124.
<https://doi.org/10.1086/209665>
- Turing, A.M., 1950. *Computing Machinery and Intelligence*. Oxford University Press, Mind, New Series, pp. 433-460. Disponível em: <<http://mind.oxfordjournals.org/cgi/doi/10.1093/mind/LIX.236.433>> [Acessado 30 julho 2022].
- Witten, I.H., Frank, E. e Hall, M.A., 2011. *Data Mining: practical machine learning tools and techniques*. Massachusetts: British Library.
- Zmijewski, M.E., 1984. *Methodological issues related to the estimation of financial distress prediction models*. Journal of Accounting Research, 22, pp. 59-82.
<https://doi.org/10.2307/2490859>