

# RISCO DE FALÊNCIA EM SETORES DE INFRAESTRUTURA: UMA ANÁLISE DE 2006 A 2018

VANDERSON A. DELAPEDRA-SILVA<sup>1</sup>

 <https://orcid.org/0000-0002-3937-9914>

**Para citar este artigo:** Delapedra-Silva, V. A. (2021). Risco de falência em setores de infraestrutura: Uma análise de 2006 a 2018. *Revista de Administração Mackenzie*, 22(4), 1–30. doi:10.1590/1678-6971/eRAMF210104

**Submissão:** 4 jun. 2020. **Aceite:** 29 out. 2020.

<sup>1</sup> Universidade de Brasília (UnB) e Banco do Brasil, Brasília, DF, Brasil.



This is an open-access article distributed under the terms of the Creative Commons Attribution License.

This paper may be copied, distributed, displayed, transmitted or adapted for any purpose, even commercially, if provided, in a clear and explicit way, the name of the journal, the edition, the year and the pages on which the paper was originally published, but not suggesting that RAM endorses paper reuse. This licensing term should be made explicit in cases of reuse or distribution to third parties.

Este artigo pode ser copiado, distribuído, exibido, transmitido ou adaptado para qualquer fim, mesmo que comercial, desde que citados, de forma clara e explícita, o nome da revista, a edição, o ano e as páginas nas quais o artigo foi publicado originalmente, mas sem sugerir que a RAM endosse a reutilização do artigo. Esse termo de licenciamento deve ser explicitado para os casos de reutilização ou distribuição para terceiros.

## RESUMO

**Objetivo:** Esta pesquisa tem como objetivo identificar a probabilidade de inadimplência de empresas de infraestrutura, considerando as especificidades setoriais de suas atividades. Além disso, o trabalho procura identificar a aplicação de variáveis estruturais de probabilidade de inadimplência em um modelo de forma reduzida, a fim de identificar a significância de seu uso. Para isso, investigamos 1.520 empresas norte-americanas de seis setores diferentes vinculados à infraestrutura.

**Originalidade/valor:** As análises realizadas para identificar a probabilidade de uma empresa falir dificilmente consideram sua particularidade setorial. Como resultado, embora a maioria dos modelos traga insumos importantes para a avaliação de riscos, a maioria deles não considera essa visão setorial. Nesse sentido, este trabalho tem como valor e originalidade contribuir para o preenchimento dessa lacuna e identificar a existência de diferenças setoriais na análise de risco de inadimplência em empresas de infraestrutura no mercado norte-americano, no período entre 2006 e 2018.

**Design/metodologia/abordagem:** O estudo realizou uma regressão logística (modelo *logit*) usando 11 variáveis do modelo estabelecidas no cálculo da probabilidade de inadimplência. O estudo também utilizou a variável distância até o *default* como variável explicativa, a fim de identificar sua capacidade de explicar o fenômeno pesquisado.

**Resultados:** O estudo identificou que, além do tamanho das empresas, a distância até o *default* é a única variável que pode ser aplicada com significância em todos os setores analisados. Além disso, constatou-se que as empresas do setor de petróleo e gás têm menos sensibilidade a essa variável do que as empresas dos outros setores.

## PALAVRAS-CHAVE

Risco setorial. Distância até o *default*. Infraestrutura. Modelo de Merton. Risco de crédito.

## 1. INTRODUÇÃO

Em um mundo cada vez mais dinâmico e em evolução, a análise do desempenho financeiro de empresas ligadas à infraestrutura desempenha um papel central para garantir o desenvolvimento econômico dos países. No entanto, a diversidade de características dos setores aos quais essas empresas estão vinculadas pode comprometer uma análise de risco eficaz. Nesse sentido, uma análise de risco capaz de identificar essas diferenças é de grande importância para que seu acesso ao crédito não seja comprometido por análises distorcidas ou padronizadas. Este artigo tem como objetivo identificar essas diferenças setoriais na mensuração do risco de inadimplência de empresas vinculadas a diferentes setores de infraestrutura utilizando um modelo de regressão logística como ferramenta. Como resultado, constatou-se a significância da variável distância até a *default* desempenhando o papel de variável explicativa do modelo. Além disso, foi possível verificar que essa variável possui sensibilidades diferentes, dependendo do setor em que é utilizada.

Um dos fatores mais sensíveis no estudo das finanças é a busca de mecanismos para estimar a probabilidade de inadimplência. Esse esforço desencadeou o surgimento de diversos modelos voltados para a solução desse problema. Entre eles, os modelos referenciados em técnicas de precificação de ativos aplicados ao estudo de passivos corporativos foram os pioneiros na tarefa de modelar a inadimplência da empresa e vinculá-la a um modelo de precificação econômica (Chen & Wu, 2014; Lando & Nielsen, 2010).

Merton (1974) contribuiu para esclarecer essa aplicação ao criar uma analogia entre a estrutura de capital das empresas e a ideia de opções sobre seus ativos. Diante disso, o patrimônio líquido de uma empresa poderia ser comparado a uma opção de compra europeia sobre seus ativos, em que o preço de exercício dessas opções seria o valor de sua dívida.

Atualmente, duas abordagens teóricas são bastante difundidas na mensuração da probabilidade de inadimplência das empresas. Uma delas baseia-se nos chamados modelos estruturais, nos quais as contribuições de Black e Scholes (1973) e Merton (1974) aprimoraram o uso de variáveis estruturais das empresas, especialmente o valor de seus ativos, para avaliar a probabilidade de risco de crédito.

A segunda abordagem baseia-se nos chamados modelos reduzidos, que permitem a análise da ocorrência de falência independentemente da evolução dos dados estruturais da empresa. Os modelos reduzidos são baseados em mecanismos voltados para a busca de taxas de risco estocásticas, em que

a dinâmica da probabilidade de inadimplência independe da taxa de recuperação de crédito (Allen & Saunders, 2002; Altman, Resti, & Sironi, 2004).

A análise da correlação entre fatores latentes dinâmicos comuns entre empresas pode explicar uma parcela considerável do risco de inadimplência, mas os fatores setoriais e macroeconômicos são geralmente ignorados pelos modelos convencionais (Chen & Wu, 2014; Duffie, Eckner, Horel, & Saita, 2009; Jorion & Zhang, 2009).

No entanto, segundo Giesecke (2004), não há pesquisas suficientes sobre abordagens que incorporem a interdependência do *default* entre as empresas. Portanto, o desenvolvimento de modelos consistentes para alcançar esse objetivo ainda é um desafio (Chen & Wu, 2014; Escribano & Maggi, 2019).

Este artigo pretende utilizar diversas variáveis explicativas para responder às seguintes questões de pesquisa:

- Quais variáveis afetam a probabilidade de inadimplência nas empresas do setor de infraestrutura da amostra analisada?
- Como os diferentes setores de infraestrutura reagem às variáveis do modelo proposto?

Este artigo está dividido em cinco partes. Além desta introdução, analisaremos alguns mecanismos de medição do risco de crédito suportados pela medição da probabilidade de *default*, que são fornecidos pelo modelo KMV-Merton, assim como os modelos *Z-score* de Altman (1968), *O-score* de Ohlson (1980) e o modelo de Zmijewski (1984). Na terceira parte, mostraremos a metodologia utilizada no estudo, bem como as fontes de dados utilizadas para a medição do impacto setorial no cálculo do risco de crédito das empresas de infraestrutura. Na quarta parte, apresentaremos os resultados e as análises, e, por último faremos as considerações finais, indicando as limitações deste estudo, bem como as sugestões de novas oportunidades de pesquisa.

## 2. RISCO DE DEFAULT

Em finanças, o termo “risco” está associado à impossibilidade de prever eventos futuros. Assim, o risco envolve a probabilidade de haver resultados diferentes dos esperados, incluindo casos negativos e positivos. Como os dois tipos de resultado fogem da expectativa, ambos são suscetíveis de ser classificados como de risco (Crosbie & Bohn, 2003; Damodaran, 2012). Diante disso, o trabalho seminal de Markowitz (1952), que associou a variância do retorno como medida de risco de investimento, tornou-se uma das

bases mais importantes para a literatura de cálculo de risco de investimento, bem como para o surgimento de novas abordagens sobre o assunto (Soleimani, Golmakani, & Salimi, 2009).

A abordagem teórica do risco de crédito pode ser dividida em pelo menos duas escolas distintas de pensamento (Allen & Saunders, 2002; Zhou, 2001). Na primeira, denominada abordagem estrutural, a análise de probabilidade de inadimplência concentra-se na evolução do valor de uma empresa. Dessa forma, o *default* ocorre quando o valor de mercado de uma empresa atinge um nível crítico, que é delimitado pelo valor de sua dívida (Duffie & Lando, 2001; Vasicek, 1984; Zhou, 2001).

A segunda geração de modelos baseia-se em modelos de forma reduzida focados na busca de taxas de risco estocásticas, em que a dinâmica da probabilidade de inadimplência independe da taxa de recuperação de crédito, e ambos não têm relação com as características estruturais da empresa. Nos modelos de forma reduzida, o foco passou a ser a avaliação do potencial de perda contratual, dado um horizonte de tempo e um nível de confiança em que o evento de *default* é visto como aleatório.

Existe ainda uma terceira geração de modelos, denominados modelos de análise temporal, que se baseiam na análise da probabilidade de ocorrência de um evento de *default* em determinado período (Duffie, Saita, & Wang, 2007).

## 2.1 KMV-Merton

O modelo KMV-Merton parte do pressuposto de que a estrutura de capital de uma empresa pode ser igualada a uma série de opções sobre seus ativos. Dessa forma, o patrimônio líquido pode ser visto como uma opção de compra sobre os ativos da empresa, e o preço de exercício pode ser representado por seu valor de dívida. Nesse sentido, o patrimônio de uma empresa é apresentado em função do valor da empresa. Então, o valor de uma empresa no tempo  $t$  pode ser dado por:

$$V_t = S_t + D_t \quad (\text{Equação 1})$$

em que:

$V_t$  = valor da empresa no tempo  $t$ ;

$S_t$  = valor do ativo da empresa; e

$D_t$  = valor da dívida débito da empresa.

A variação dinâmica do valor da empresa, por sua vez, pode ser definida pela equação diferencial estocástica que define um processo browniano geométrico.



$$dV_t = \mu V_t d_t + \sigma V_t dW_t \quad (\text{Equação 2})$$

em que:  $\mu$  representa a taxa de crescimento esperada para o valor da empresa por unidade de tempo;  $\sigma V_t$ , a volatilidade do valor da empresa em um determinado período; e  $dW_t$ , o movimento browniano geométrico.

Uma vez que o patrimônio da empresa é tratado como uma opção de compra sobre o seu valor e o preço de exercício é dado pelo valor de face de suas obrigações, o patrimônio pode ser apresentado, em função do valor da empresa, da seguinte forma:

$$E = V \mathcal{N}(d_1) - e^{-rT} F \mathcal{N}(d_2) \quad (\text{Equação 3})$$

em que:  $E$  expressa o valor do patrimônio da empresa;  $F$ , o valor de face de sua dívida;  $r$ , a taxa livre de risco;  $\mathcal{N}$  representa a função de distribuição normal padronizada acumulada; e  $d_1$  é dado por:

$$\ln\left(\frac{V}{F}\right) + (r + 0,5\sigma_v^2)T \quad (\text{Equação 4})$$

E o termo  $d_2$  é dado pela seguinte equação:

$$d_2 = d_1 - \sigma_v \sqrt{T} \quad (\text{Equação 5})$$

O modelo também relaciona a volatilidade do valor da empresa com a volatilidade de seu patrimônio.

$$\sigma_E = \left(\frac{V}{E}\right) \frac{\partial E}{\partial V} \sigma_v \quad (\text{Equação 6})$$

Uma vez que o modelo Black-Scholes-Merton (BSM) demonstra que  $(\partial E / \partial V) = \mathcal{N}(d_1)$ , então:

$$\sigma_E = \left(\frac{V}{E}\right) \mathcal{N}(d_1) \sigma_v \quad (\text{Equação 7})$$

Bharath e Shumway (2008) ressaltam que o modelo utiliza duas equações não lineares (3 e 7) para expressar o valor da volatilidade do patrimônio da empresa dentro de uma determinada probabilidade de *default*.



Diferentemente do valor total da empresa, o valor da opção pode ser relacionado ao valor do seu patrimônio, sendo a variação desse patrimônio estimada a partir de retornos anteriores. Ao mesmo tempo, as obrigações da empresa podem ser relacionadas ao valor de face de suas dívidas.

O valor de uma empresa pode ser representado pelo preço pelo qual todos os títulos dessa empresa podem ser comprados ou vendidos. O cálculo do valor de mercado dos ativos da empresa difere do valor contábil desses ativos, visto que o valor de mercado considera seu potencial de desempenho futuro (Allen & Saunders, 2002). Vasicek (1984) aponta que ambas as ações podem ser obtidas multiplicando-se o número de ações da empresa pelo seu preço, e o valor das dívidas pode ser medido pelo preço da dívida a taxas de juros nominais.

Acrescentando-se uma taxa livre de risco, além das estimativas levantadas anteriormente, é possível resolver as equações 3 e 7 simultaneamente, obtendo os valores de  $V$  e  $\sigma_V$ , para que finalmente se possa calcular a distância até o *default* (DD).

$$DD = \frac{\ln\left(\frac{V}{F}\right) + (\mu - 0,5\sigma_V^2)T}{\sigma_V\sqrt{T}} \quad (\text{Equação 8})$$

em que  $\mu$  representa uma estimativa do retorno anual dos ativos da empresa.

O uso da DD tem sido criticado por sua pouca precisão e eficiência na tarefa de previsão de *default* corporativo. Esse fato tem pressionado o surgimento de outras alternativas capazes de superar essa lacuna (Bharath & Shumway, 2008; Chen & Wu, 2014).

Os pressupostos da DD de Merton, que assumiu como padrão o movimento browniano geométrico para medir o valor de mercado da empresa, além de ter assumido um padrão de uniformidade temporal para a mensuração de suas dívidas, abrem caminho para que modelos mais reduzidos possam explicar a probabilidade de *default*. Esses modelos se baseiam na mensuração da probabilidade de que o valor da empresa tem de ser menor que o valor de face de sua dívida, dado um horizonte de tempo (Bharath & Shumway, 2008).

Finalmente, o modelo de Merton postula que a probabilidade de inadimplência (*probability of default* – PD) é a diferença entre a função de probabilidade de uma distribuição normal e a DD.

$$PD = \mathcal{N}(-DD) \quad (\text{Equação 9})$$



Bharath e Shumway (2008) destacam que esse modelo emprega duas equações não lineares para expressar o valor da volatilidade do patrimônio da empresa dentro de uma certa probabilidade de *default*. A utilização de uma taxa livre de risco associada às premissas do valor patrimonial da empresa permite o cálculo do DD, medida que expressa a distância que uma empresa tem até a inadimplência.

O KMV pode ser entendido como uma extensão do modelo de Merton e emprega a mesma lógica de modelagem da avaliação de ativos da empresa e sua capacidade de superar o valor limite de suas dívidas. Uma das variações do modelo KMV-Merton também é empregada pela agência de classificação de crédito norte-americana Moody's. O modelo utilizado por essa empresa também pode ser denominado modelo KV, e uma das diferenças básicas dessa versão é que ela se baseia na mensuração de várias classes e vencimentos de dívidas em vez de considerá-los fixos no tempo (Bharath & Shumway, 2008; Kliestik, Misankova, & Kocisova, 2015).

Bharath e Shumway (2008) adaptaram o modelo KMV-Merton para criar uma alternativa que os autores chamaram de *naïve*, em que aproximam o valor de mercado da dívida de seu valor de face e com isso chegam ao valor e à variação de mercado dos ativos por meio de uma ponderação da variação patrimonial da empresa.

Esse ajuste permitiu uma melhora no desempenho do modelo Merton-KMV quando utilizado como variável explicativa da previsão de inadimplência; segundo os autores, o modelo KMV-Merton *naïve* poderia ser expresso da seguinte forma:

$$Naïve\sigma_D = 0,05 + 0,25\sigma_E \quad (\text{Equação 10})$$

em que:

$$Naïve\sigma_V = \frac{E}{E+F}\sigma_E + \frac{F}{E+F}(0,05 + 0,25\sigma_E) \quad (\text{Equação 11})$$

em que:  $\mu = r_{it-1}$ .

Então os resultados da DD *naïve* podem ser expressos da seguinte forma:

$$Naïve DD = \frac{\ln\left(\frac{E+F}{F}\right) + (r_{it-1} - 0,5Naïve\sigma_V^2)T}{Naïve\sigma_V\sqrt{T}} \quad (\text{Equação 12})$$



## 2.2 Os modelos reduzidos de Altman (1968), Ohlson (1980) e Zmijewski (1984)

Os modelos de forma reduzida podem ser considerados uma evolução dos modelos estruturais, que relacionavam a inadimplência à queda do valor de mercado dos ativos da empresa abaixo de um determinado nível, normalmente o valor de sua dívida. Assim, como os modelos reduzidos, as variáveis latentes também passaram a ser utilizadas como preditoras de inadimplência (Duffie & Lando, 2001). O primeiro modelo univariado moderno de previsão de *default* concluiu que o fluxo de caixa sobre a dívida total pode ser considerado a variável explicativa mais relevante nessa previsão (Beaver, McNichols, & Rhie, 2005; Hillegeist, Keating, Cram, & Lundstedt, 2004).

Nesse sentido, Altman (1968) propôs um modelo multivariado que poderia explicar o *default* corporativo por meio do método de análise discriminante (Lando & Nielsen, 2010). Altman (1968) desenvolveu um modelo denominado *Z-score*, que se baseia nas variáveis de maior significância em um modelo de análise discriminante multivariada. Assim, a análise é expressa por  $Z = v_1x_1 + v_2x_2 + \dots + v_nx_n$ , em que os valores das variáveis são transformados em uma sequência discriminante de *Z* (Allen & Saunders, 2002; Hillegeist et al., 2004; Taffler, 1984).

Além disso,  $v_1, v_2, \dots, v_n$  são coeficientes discriminantes, e  $x_1, x_2, \dots, x_3$  são variáveis independentes. A função discriminante final proposta por Altman (1968) é expressa por:

$$Z = 0,12X_1 + 0,14X_2 + 0,33X_3 + 0,006X_4 + 0,999X_5 \quad (\text{Equação 13})$$

em que:

$X_1 = \textit{capital de giro/ativos totais}$ : medindo ativos líquidos em relação ao tamanho da empresa;

$X_2 = \textit{lucros retidos/ativos totais}$ : medindo a lucratividade que reflete a idade da empresa e o potencial de ganhos;

$X_3 = \textit{Ebit/ativos totais}$ : medindo a eficiência operacional sem impacto de impostos e fatores de alavancagem. Nesse caso, o lucro operacional é considerado muito importante para analisar a viabilidade de longo prazo;

$X_4 = \textit{patrimônio líquido/passivo total}$ : medindo a dimensão de mercado da empresa. Nesse caso, o patrimônio líquido considerado é o valor de mercado do patrimônio líquido;

$X_5 = \textit{vendas ativos totais}$ : medindo o giro total de ativos.

Propondo um aprimoramento desse modelo, Ohlson (1980) adotou a regressão logística em substituição à análise linear discriminante anteriormente adotada por Altman (1968), e o modelo passou a ser denominado *O-Score* (Jayasekera, 2018; Lando & Nielsen, 2010). O modelo de Ohlson (1980) também possibilitou identificar elementos que influenciam estatisticamente na probabilidade de inadimplência das empresas no período de um ano, tais como: o porte da empresa, medidas de estrutura financeira, medidas de desempenho e medidas relacionadas à liquidez corrente da empresa. Esse modelo foi baseado na observação de 105 empresas que faliram em comparação com 2.058 empresas que não entraram em falência. Em seguida, o autor propôs três modelos com diferentes variáveis dependentes, são elas: 1. previsão de falência em um ano; 2. previsão de falência em dois anos, visto que a empresa não falirá nos anos subsequentes; e 3. previsão de falência em um ou dois anos. Nas variáveis explicativas dos modelos, estão:

SIZE = log (ativos totais/índice de preços);

TLTA = passivo total/ativos totais;

WCTA = capital de giro/ativos totais;

CLTA = passivo circulante/ativos totais;

OENEG = 1 se o passivo exceder o ativo e 0 se não;

NITA = lucro líquido/ativos totais;

FUTL = fluxo de caixa operacional/passivo total;

INTWO = 1 se o lucro líquido foi negativo para os últimos dois últimos anos e 0 caso contrário; e

CHIN =  $(NI - NI(t - 1)) / (|NI| + |NI(t - 1)|)$ , em que *NI* representa o lucro líquido do período mais recente. Dessa forma, o denominador teria como premissa atuar como nivelador e a variável, como medida da variação do lucro líquido.

Sendo  $X_i$  um vetor de variáveis preditoras para a  $i^{\text{ésima}}$  observação,  $\beta$  um vetor de parâmetro desconhecido e  $P(X_i, \beta)$  a probabilidade de *default* para cada  $X_i$  e  $\beta$ ; e  $P$  representa uma função logarítmica de probabilidade entre  $0 \leq P \leq 1$ .

$$l(\beta) \equiv \sum_{i \in S_1} \log P(X_i, \beta) + \sum_{i \in S_2} \log(1 - P(X_i, \beta)) \quad (\text{Equação 14})$$

em que:  $S_1$  representa o número de empresas que faliram; e  $S_2$ , o número de empresas que não faliram em um determinado período.



Zmijewski (1984), por sua vez, estendeu a abordagem de Ohlson (1980) para implementar um modelo *probit* como alternativa metodológica para o cálculo do risco de inadimplência (Jones & Hensher, 2008; Platt & Platt, 1990). Em seu modelo, Zmijewski (1984) aplica as seguintes variáveis explicativas que influenciam a probabilidade de uma empresa entrar no padrão.

$$B = \alpha_0 + \alpha_1 ROA + \alpha_2 FINL + \alpha_3 LIQ \quad (\text{Equação 15})$$

em que:

B = 1 se a empresa entra em *default* e 0 se não;

ROA = lucro líquido/ativos totais;

FINL = dívidas totais/ativos totais; e

LIQ = ativos correntes/passivo total.

Por fim, vale ressaltar que os modelos destacados por Altman (1968), Ohlson (1980) e Zmijewski (1984) são modelos estáticos e não consideram as mudanças que ocorrem na empresa ao longo do tempo. Essa característica produz algumas inconsistências na estimativa da probabilidade de inadimplência (Shumway, 2001).

### 2.3 Modelos temporais

Segundo Duffie et al. (2007), ainda existe uma terceira geração de modelos denominada modelos de análise temporal. Esses modelos surgiram para avaliar eventos de risco na área de finanças por Lane, Looney e Wansley (1986). Posteriormente, Lee e Urrutia (1996) compararam um modelo de duração com um modelo *logit* de previsão de *default* de seguradoras e concluíram que esses modelos são superiores na identificação de variáveis mais significativas do que o modelo *logit*.

Segundo Shumway (2001), ao ignorarem as mudanças das empresas ao longo do tempo, os modelos estáticos que estimam a probabilidade de inadimplência são enviesados e sem consistência. Nesse sentido, o autor desenvolveu um modelo que investiga diversas informações disponíveis para calcular o risco de inadimplência das empresas a partir de cada momento, uma abordagem comparável a um modelo *logit* multiperíodo (Duffie et al., 2007).

Hillegeist et al. (2004) também usaram um modelo de tempo discreto para estimar o risco de inadimplência. Em seu modelo, os autores combinaram variáveis macroeconômicas e contábeis com a variável DD para explicar a variação das probabilidades de *default* entre as empresas.

Nesse tema, LeClere (2005) revisa um modelo de risco proporcional e compara a escolha de covariáveis dependentes do tempo com as covariáveis não dependentes do tempo. O autor sugere que a escolha de covariáveis com dependência temporal influencia substancialmente a estimação de modelos dessa natureza.

Por fim, os modelos de risco proporcional são muito populares na pesquisa de riscos de inadimplência, por causa, principalmente, de duas características: a primeira é o fornecimento de informações sobre o tempo decorrido entre um determinado ponto de origem e a ocorrência de um evento, e, quanto à segunda, em contraste com a maioria dos demais modelos de análise de sobrevivência, os modelos de risco proporcional são semiparamétricos, não exigindo a especificação de uma única distribuição para modelar a relação entre eventos e tempo (LeClere, 2005).

## 3. DESENVOLVIMENTO E INFRAESTRUTURA

O termo infraestrutura pode ser entendido como um conjunto de estruturas e redes que conectam cidades e áreas metropolitanas às atividades sociais e econômicas. Alguns exemplos de infraestrutura são: construção de ruas, estradas, saneamento básico, telecomunicações etc. (Grimsey & Lewis, 2002).

Qualquer projeto básico de crescimento econômico de um país precisa levar em consideração alternativas de investimentos estratégicos em infraestrutura. Esses podem ser concebidos com o intuito de manter o que já foi construído ou como ampliação de novos investimentos. Assim, é fundamental que os investimentos em infraestrutura sejam concebidos de forma a contemplar informações estratégicas, como prioridades, papel do setor privado, fontes de financiamento, requisitos de qualidade, entre outras (Ruiz-Nuñez & Wei, 2015).

### **3.1 Financiamento à infraestrutura**

Os projetos de infraestrutura são marcados por demandar um grande montante de capital com prazos de pagamento diluídos em um horizonte de longo prazo, como dificuldades que abrem caminho para parcerias entre agentes públicos e privados para que a operação dos serviços de infraestrutura seja financeiramente sustentável (Smithson & Hayt, 2001).

Até os anos 1990, os governos eram os maiores investidores em infraestrutura no mundo. No entanto, a falta de capital público disponível para financiar as construções, principalmente em países em desenvolvimento,

impulsionou a utilização de investimentos do setor privado nesses projetos, contribuindo para a redução dos riscos associados à ineficiência da gestão (Grimsey & Lewis, 2002; Kumari & Sharma, 2017).

A partir do ano 2000, as limitações causadas por regulamentações mais rígidas de capital, além das mudanças no ambiente macroeconômico e da ineficiência da gestão pública, têm incentivado uma maior participação de investidores institucionais nesses projetos (Della Croce & Gatti, 2014).

Nesse sentido, Sharma e Vohra (2008) destacam a importância do investimento privado em infraestrutura, o qual não só proporciona o grande montante de capital necessário nesses projetos, mas também viabiliza técnicas operacionais mais eficazes, melhora a capacidade de cumprimento de prazos e oferece tecnologias mais inovadoras.

Alternativamente, as parcerias público-privadas (PPP) também possibilitaram contornar o problema de falta de recurso público. Adicionalmente, sua constituição alinha interesses públicos e privados em projetos de infraestrutura. As PPP são pautadas pela promoção de maior transparência, maior eficiência na prestação de serviços de infraestrutura e maior conformidade entre os responsáveis por esses serviços (Grimsey & Lewis, 2002; Mustafa, 1999).

Apesar de as diferenças de interesses entre agentes públicos e privados representarem um problema para o desenvolvimento de PPP, como ferramentas de financiamento de infraestrutura (Hart, Shleifer, & Vishny, 1997; Mustafa, 1999), o estabelecimento de uma estrutura institucional coesa, além de mecanismos contratuais que mitiguem essas distorções, pode contribuir para a superação desses impasses (Mustafa, 1999).

### **3.2 Influência setorial no cálculo de *default***

As investigações de inadimplência sempre levaram em conta uma análise individual das empresas, ao medirem o impacto de variáveis específicas na probabilidade de falência e ignorarem os fatores presentes na inter-relação entre elas (Hertzel & Officer, 2012; Platt & Platt, 1991).

Dessa forma, o cálculo de índices relativos por setor industrial (valor do dividido pela média do valor do setor) foi uma alternativa encontrada para mitigar essas distorções. Platt e Platt (1991) compararam modelos contendo esses indicadores relativos a modelos sem esse ajuste e concluíram que modelos contendo indicadores com medidas relativas são mais eficazes do que modelos com indicadores sem ajuste setorial.

Com o surgimento dessa adaptação, despontaram novos estudos sobre modelagem de risco de crédito, o que possibilitou a combinação do uso de

variáveis explicativas estruturais e indicadores setoriais agregados para mensurar a inadimplência das empresas (Izan, 1984; Platt & Platt, 1990). Além disso, outras alternativas capazes de capturar a correlação de fragilidades comuns entre as empresas também contribuíram para a investigação da influência setorial no desempenho empresarial.

Nesses casos, dois mecanismos distintos podem mostrar a correlação de inadimplência entre as organizações: o primeiro se baseia no reconhecimento de que a saúde financeira de qualquer empresa está correlacionada a fatores macroeconômicos, e o segundo está fundamentado nas ligações diretas não mensuradas entre as firmas. O segundo mecanismo merece maior atenção por conta do potencial de contágio prejudicial entre as empresas (Giesecke, 2004; Pu & Zhao, 2012).

Duffie e Garleanu (2001) e Jarrow e Yu (2001) sugerem que essa correlação de *default* pode ser induzida pela intensidade existente entre os eventos de *default* das empresas, o que seria capaz de expor a dependência de fatores comuns de *default*.

Koopman, Lucas e Schwaab (2012) identificaram a influência dos riscos sistêmicos na variação do risco de inadimplência. Para os autores, os fatores sistêmicos correspondem a cerca de 35% da variação da taxa de insolvência das empresas norte-americanas, sendo 25% derivados de fragilidades setoriais. A acumulação de riscos sistemáticos também é evidente em períodos anteriores e durante as crises financeiras.

Chen e Wu (2014) enfatizam ainda que os modelos convencionais de previsão de *default* subestimam a influência de fatores não observáveis nas correlações de insolvência das empresas. As fragilidades observáveis em fatores macroeconômicos e setoriais têm forte influência na intensidade da insolvência.

Em contrapartida, Duffie et al. (2007) utilizaram um modelo sensível às variações temporais para estimar a probabilidade de inadimplência de empresas do setor de máquinas e instrumentos industriais, e identificaram que o desempenho de medidas de lucros setoriais, medido a partir da média dos lucros no setor ao qual as empresas pertencem, tem significado apenas quando utilizado de forma isolada.

Quando a variável relacionada aos lucros setoriais foi utilizada em conjunto com a variável DD e o crescimento da receita das empresas individuais, o seu desempenho não se mostra significativo (Duffie et al., 2007).

Por fim, a inclusão de efeitos setoriais no cálculo do risco de inadimplência das empresas tem destacado cada vez mais a importância desse mecanismo para aprimorar os modelos de previsão de falências. Além disso,

a clara existência de fatores de risco de inadimplência comuns relacionados ao setor industrial pode ser uma forma de evitar que as taxas de inadimplência sejam erroneamente estimadas, além de contribuir para o surgimento de ferramentas de predição padrão mais eficientes.

## 4. METODOLOGIA

Segundo Jayasekera (2018), alguns caminhos metodológicos contribuíram para o exercício de predição de uma empresa, como modelos matemáticos, modelos baseados em redes neurais, modelos baseados no mercado e modelos estatísticos, como regressões *logit/probit*, e modelos de discriminantes determinações (Allen & Saunders, 2002).

Portanto, este trabalho adota o modelo de regressão logística (*logit*) utilizado em situações em que a variável dependente é categórica binária e as demais variáveis podem ser numéricas e categóricas.

### 4.1 Modelo *logit*

Os modelos lineares de probabilidade de inadimplência usam dados anteriores para explicar os dados de pagamento de empréstimos anteriores e, em seguida, estimar as probabilidades de inadimplência em empréstimos futuros. Porém, quando se avalia a ocorrência ou não ocorrência de um determinado evento, as probabilidades estimadas de inadimplência podem estar fora da faixa 0 e 1, trazendo informações que não são relevantes para a análise (Altman & Saunders, 1997; Saunders & Thomas, 1997).

Para superar esse problema, os modelos *logit* e *probit* permitem que a variável dependente assuma um formato de escolha binária qualitativa, que indica a ocorrência ou não de um determinado evento, como o *default* de uma empresa (Wooldridge, 2010).

Em uma regressão logística, o foco é baseado na transformação logística de  $\pi(x)$ , dado por:

$$g(x) = \ln \left[ \frac{\pi(x)}{1 + \pi(x)} \right] = \beta_0 + \beta_1 x \quad \text{Equação 16}$$

O método utilizado para estimar os parâmetros dos modelos de regressão logística é o método da máxima verossimilhança, que tem por objetivo produzir valores para os parâmetros capazes de maximizar a probabilidade de obtenção do conjunto de dados observados.

## 4.2 Modelo e variáveis

Na elaboração deste ensaio, utilizamos dados de balanços, demonstrativos de resultado do exercício e cotação de ações de empresas norte-americanas listadas em bolsas de valores pertencentes a subgrupos específicos de infraestrutura, com base no *Global Industry Classification Standard (Gics)*. Assim, as variáveis contábeis pertencentes aos modelos de Altman (1968) e Zmijewski (1984) e uma variável apontada por Lennox (1999) foram consideradas as mais relevantes para esses tipos de modelo. Portanto, incluíram-se esses tipos no modelo deste estudo.

**(Figura 4.2.1)**  
**VARIÁVEIS**

Nome	Origem	Variável
Tamanho	Altman (1968)	SZ
Capital de giro/ativos totais	Altman (1968)	WK
Lucros retidos/ativos totais	Altman (1968)	RE
Ebit/ativos totais	Altman (1968)	EB
Valor de mercado do patrimônio líquido/ passivo total	Altman (1968)	EQ
Vendas/ativos totais	Altman (1968)	SL
Lucro líquido/ativos totais	Zmijewski (1984)	NI
Passivo total/ativos totais	Zmijewski (1984)	LA
Ativo circulante/passivo circulante	Zmijewski (1984)	LI
Fluxo de caixa/passivo total	Beaver (1967)	CF
Distância até o <i>default</i>	Duffie et al. (2007)	DD

Fonte: Elaborada pelo autor.

Além dessas variáveis contábeis, o modelo incluiu o tamanho da firma (SZ) (Ohlson, 1980; Lennox, 1999; Shumway, 2001), dado pelo logaritmo natural de seus ativos.

A inclusão da variável explicativa DD foi justificada pelos trabalhos de Duffie et al. (2007) e Kealhofer (2003), que encontraram uma dependência significativa das probabilidades de falência futura nessa variável.

A variável DD foi calculada com base na proposta de Bharath e Shumway (2008), que, a partir de um modelo *naïve*, atingiu um resultado superior



sem a necessidade de operações iterativas entre as variáveis da volatilidade dos preços dos ativos e o valor de mercado da empresa. Neste trabalho, o componente de volatilidade das ações  $\sigma$  foi obtido pelo desvio padrão trimestral da lucratividade dos preços diários das ações. A taxa do ativo livre de risco utilizada na variável DD foi a média trimestral do trimestre anterior (*1-year treasury constant maturity rate*), conforme sugerido por Bharath e Shumway (2008).

A variável valor de mercado do patrimônio líquido também foi baseada no trabalho de Bharath e Shumway (2008), em que é expressa pelo valor do preço do ativo multiplicado pelo número de ações negociadas. No caso deste estudo, utilizou-se a média trimestral dos preços das ações das empresas multiplicada pela quantidade de ações negociadas nesse período.

$$\eta = \alpha + \beta_0 SZ + \sum_{j=1}^5 \beta_j Dummy_i + \beta_6 WK + \beta_7 RE + \beta_8 EB + \beta_9 EQ + \beta_{10} SL + \beta_{11} NI + \beta_{12} LA + \beta_{13} LI + \beta_{14} CF + \beta_{15} DD + \varepsilon_{it} \quad \text{Equação 17}$$

Para identificar características específicas entre os setores, foram incluídas cinco variáveis *dummy*, representando cada um dos seis subgrupos selecionados na amostra.

### 4.3 Base de dados

A base de dados utilizada para a análise foi extraída da Bloomberg e composta pelas informações contábeis do balanço e conta de ganhos e perdas de 1.520 empresas e 24 variáveis, totalizando um universo de 79.040 observações do período de 2006 a 2018, trimestralmente. As informações da amostra inicial referem-se a empresas norte-americanas pertencentes a seis segmentos específicos do setor de infraestrutura, com base no Gics, a saber: água e saneamento (SAN), eletricidade, energia elétrica renovável (ENR), logística e transporte (LOG), petróleo e gás (PET), além de telecomunicações (TEL).

As concessionárias de gás foram excluídas da base de dados, bem como as empresas que continham diversas atividades nesses setores. A justificativa para essa exclusão baseou-se na baixa representatividade dessas atividades em setores denominados de infraestrutura, bem como em empresas que possuíam informações mistas sobre sua atividade. O período analisado foi do primeiro trimestre de 2006 ao quarto trimestre de 2018, com periodicidade de 48 trimestres.

A falta de constância temporal dos dados, com muitas perdas de informação ao longo dos trimestres, comprometeu a análise longitudinal da amostra. Para tanto, foi necessário fazer alguns ajustes na base de dados, como resumir as informações ao longo do tempo e aplicar a média de cada uma das variáveis de interesse por empresa.

## 5. RESULTADOS E DISCUSSÃO

Os dados apresentaram 404 empresas com valores faltantes em pelo menos uma das variáveis. Da mesma forma, os setores de água e saneamento e energia elétrica não apresentaram nenhum evento falimentar ao longo do período, sendo retirados das observações. Em suma, a análise final teve um conjunto de 1.066 empresas.

Identificaram-se valores extremos em algumas variáveis, e, para evitar o descarte dos dados amostrados, bem como a incidência de *outliers*, os valores das variáveis foram truncados no nonagésimo nono e primeiro percentis, conforme sugerido por Shumway (2001).

(Figura 5.1)

### ANÁLISE AMOSTRAL

	Variáveis	N	%
Setor	ENR	50	4,69%
	LOG	98	9,19%
	PET	842	78,99%
	TEL	76	7,13%
Default	Sim	100	9,38%
	Não	966	90,62%

Fonte: Elaborada pelo autor.

É importante notar que os setores de água e saneamento, além dos setores de energia, contavam com 27 e 65 empresas, respectivamente. Ademais, a intenção de separar as empresas de energia em dois setores distintos (energia e energias renováveis) foi aprimorar o detalhamento da análise. Porém, dentro desses setores, não havia classificação capaz de permitir um maior detalhamento quanto à geração, transmissão ou distribuição de energia, nem quanto à sua fonte de energia.

(Figura 5.2)

## VARIÁVEIS DESCRITIVAS

Variáveis	N	Média	DP	Mín.	1° Q	2° Q	3° Q	Máx.
SZ	1.066	1,86	1,55	-1,81	0,66	2,2	3,13	4,68
WK	1.066	-19,03	111,2	-934,39	-0,33	-0,01	0,11	0,58
RE	1.066	-163,92	910,56	-7571,15	-5,19	-0,46	0	0,66
EB	1.066	-1,96	10,4	-83,31	-0,12	-0,01	0,01	0,09
SL	1.066	0,2	0,4	0	0,03	0,08	0,19	2,93
NI	1.066	-2,53	13,54	-109,04	-0,15	-0,02	0,01	0,39
LA	1.066	20,79	113,75	0,07	0,4	0,59	1,02	938,85
LI	1.066	3,83	8,16	0,04	0,85	1,51	3,01	57,29
CF	1.066	-1,69	8,53	-68,1	-0,28	0,05	0,21	2,26
DD	1.066	7,860,62	60,177,4	6,37	85,68	357,71	915,83	567.420,4
EQ	1.066	10.662,05	76.237,76	0,12	1,82	5,91	55,06	691.468,2

Fonte: Elaborada pelo autor.

A Figura 5.3 mostra como a inadimplência é distribuída entre os setores. Verificou-se que o setor petrolífero apresentou o maior percentual de falência (10,1%), enquanto o setor de energias renováveis obteve o menor (4%), porém não houve diferença significativa ( $p$ -valor = 0,460) entre os percentuais de falência pelo teste exato de Fisher.

(Figura 5.3)

## VARIÁVEIS DESCRITIVAS

Setores	Default				p-valor
	Não		Sim		
	N	%	N	%	
PET	757	89,90%	85	10,10%	0,46
ENR	48	96,00%	2	4,00%	
LOG	90	91,80%	8	8,20%	
TEL	71	93,40%	5	6,60%	

Fonte: Elaborada pelo autor.

Na análise comparativa entre as empresas que faliram e não faliram, o destaque fica por conta das variáveis: SZ, EB, LA e EQ.

Na Figura 5.3, é possível verificar como são apresentadas as variáveis quantitativas com relação à falência, bem como o p-valor do teste não paramétrico de Mann-Whitney.

Verifica-se que pelo menos 50% das empresas que faliram apresentaram a variável SZ com valores inferiores ou iguais a 2,63, enquanto, entre as que não faliram, pelo menos 50% apresentaram essa variável com números inferiores ou iguais a 1,93.

Além disso, na variável EB, verificou-se que pelo menos 50% das empresas que faliram apresentaram valores inferiores ou iguais a -0,02, enquanto, entre as que não faliram, 50% apresentaram essa variável com números inferiores ou iguais a -0,01.

A variável LA também apresentou significância quando se compararam as amostras. Pelo menos 50% das empresas que faliram apresentaram a variável LA com valores inferiores ou iguais a 0,73, enquanto, entre as que não faliram, pelo menos 50% apresentaram a variável LA com valores inferiores ou iguais a 0,58.

Por fim, pelo menos 50% das empresas que faliram apresentaram a variável EQ inferior ou igual a 2,87, enquanto, entre as que não faliram, pelo menos 50% apresentaram essa variável com números inferiores ou iguais a 6,43.

Os demais preditores não apresentaram diferença significativa entre as empresas que faliram e não faliram. A matriz de correlação apresentada na Figura 5.4 destaca a existência de multicolinearidade entre diversas variáveis. Houve tanto alta correlação positiva entre algumas variáveis, como WK e RE, além de NI e EB, quanto alta correlação negativa, como LA e WK.

O modelo proposto inicialmente, expresso na Figura 5.5, reforça a evidência de que várias variáveis preditoras não foram significativas para explicar a falência (p-valor  $\geq 0,05$ ).

Além disso, o resultado do *variance inflation factor* (VIF) maior que 10 ressaltou o problema de multicolinearidade entre as variáveis do modelo.

Em relação aos resultados do *odds ratio* (OR), verificou-se que a variável SZ foi expressiva, o que significa que o aumento em uma unidade dessa variável, mantendo as demais variáveis constantes, aumenta a chance de falha em 41,3%.

O coeficiente da variável DD foi multiplicado por 100 para facilitar a interpretação. Os resultados indicam que o aumento em 100 unidades, também mantido o resto constante, diminui a chance de falência em 6,6%.

(Figura 5.4)

**MATRIZ DE CORRELAÇÃO**

SZ													
SZ	1,00	WK											
WK	0,31	1,00	RE										
RE	0,32	0,90	1,00	EB									
EB	0,34	0,74	0,73	1,00	SL								
SL	-0,08	-0,16	-0,19	-0,29	1,00	NI							
NI	0,34	0,80	0,77	0,93	-0,23	1,00	LA						
LA	-0,32	-0,99	-0,91	-0,76	0,16	-0,82	1,00	LI					
LI	-0,14	0,01	-0,01	0,06	-0,11	0,06	-0,01	1,00	CF				
CF	0,35	0,50	0,56	0,60	-0,14	0,58	-0,52	-0,02	1,00	DD			
DD	-0,16	-0,23	-0,20	-0,20	0,07	-0,20	0,22	0,08	-0,12	1,00	EQ		
EQ	-0,17	-0,09	-0,08	-0,13	0,00	-0,10	0,10	0,00	-0,23	0,07	1,00		

Fonte: Elaborada pelo autor.

(Figura 5.5)

**VARIÁVEIS DESCRITIVAS**

Variáveis	Modelo inicial			
	$\beta$	IC	OR	p-valor
(Intercepto)	-2,405	[-2,92; -1,92]	-	0
SZ	0,346	[0,16; 0,54]	1,413	0
Setor = PET	-	-	-	-
Setor = ENR	-1,005	[-2,85; 0,23]	0,366	0,178
Setor = LOG	-0,429	[-1,28; 0,3]	0,651	0,281
Setor = TEL	-0,559	[-1,66; 0,32]	0,572	0,259
WK	0,006	[-0,01; 0,02]	1,006	0,4
RE	0	[0,00; 0,00]	1	0,547
EB	-0,066	[-0,19; 0,00]	0,936	0,109

(continua)

**(Figura 5.5 (conclusão))**  
**VARIÁVEIS DESCRITIVAS**

Variáveis	Modelo inicial			
	$\beta$	IC	OR	p-valor
SL	0,188	[-0,44; 0,72]	1,207	0,52
NI	0,043	[-0,01; 0,15]	1,043	0,244
LA	0,005	[-0,01; 0,02]	1,005	0,513
LI	-0,047	[-0,12; 0,00]	0,954	0,111
CF	0,01	[-0,04; 0,06]	1,01	0,686
DD/100	-0,069	[-0,12; -0,02]	0,934	0,007
EQ	0	[0,00; 0,00]	1	0,445
Hosmer-Lemeshow			0,364	
Maior VIF			48,358	
AUC			0,695	

Fonte: Elaborada pelo autor.

A partir dos resultados obtidos, o método *backward* foi aplicado para remover as variáveis com problema de multicolinearidade. Apenas as variáveis SZ, EB e DD permaneceram significativas.

O valor de  $p$  do teste de Hosmer-Lemeshow apresentou valor maior que 0,05 em ambos os casos, demonstrando que os dois modelos são adequados.

Permanecendo fixas todas as demais variáveis, verificou-se que, quando se aumenta uma unidade da variável SZ, a chance de inadimplência também aumenta em 46,8% no modelo ajustado.

Além disso, após o ajuste do modelo, a variável EB passou a ser significativa, indicando que seu aumento em uma unidade, enquanto as demais variáveis permanecem fixas, eleva a chance de falência em 2,3%.

O modelo ajustado também mostrou que com o aumento de 100 unidades da variável DD, permanecendo as demais variáveis fixas, a chance de falência diminui 6,5%.

(Figura 5.6)  
VARIÁVEIS DESCRITIVAS

Variáveis	Modelo final			
	$\beta$	IC	OR	p-valor
(Intercepto)	-2,721	[-3,16; -2,32]	-	0
SZ	0,384	[0,20; 0,57]	1,468	0
Sector = PET				
Sector = ENR				
Sector = LOG				
Sector = TEL				
WK				
RE				
EB	-0,024	[-0,04; 0,00]	0,977	0,012
SL				
NI				
LA				
LI				
CF				
DD/100	-0,067	[-0,12; -0,02]	0,935	0,008
EQ				
Hosmer-Lemeshow	0.361			
Maior VIF	1.729			
AUC	0.67			

Fonte: Elaborada pelo autor.

Por fim, após a identificação do segundo modelo, verificaram-se as diferenças entre os setores PET e não PET. Para isso, o modelo final foi ajustado para cada um dos setores, comparando-se as estimativas pontuais e intervalares dos coeficientes de regressão.

(Figura 5.7)

**EMPRESAS DE PETRÓLEO X NÃO PETRÓLEO**

Variáveis	Empresas de petróleo e gás				Empresas exceto de petróleo e gás			
	$\beta$	IC	OR	p-valor	$\beta$	IC	OR	p-valor
(Intercepto)	-2,729	[-3,22; -2,29]	-	0	-2,713	[-3,87; -1,79]	-	0
SZ	0,403	[0,20; 0,62]	1,497	0	0,445	[0,02; 0,89]	1,561	0,043
EB	-0,022	[-0,04; 0,00]	0,978	0,048	-0,028	[-0,06; 0,01]	0,973	0,111
DD/100	-0,054	[-0,11; -0,01]	0,948	0,038	-0,203	[-0,42; -0,02]	0,816	0,036
Hosmer-Lemeshow				0,299				0,247
Maior VIF				1,688				1,806
AUC				0,667				0,714

Fonte: Elaborada pelo autor.

O pequeno número de empresas em cada setor tornou a análise específica de cada um deles inviável do ponto de vista estatístico. Entretanto, a separação entre os dois grupos (empresas de petróleo e empresas exceto de petróleo) possibilitou a obtenção de informações mais seguras e claras.

## 6. CONCLUSÃO

Este estudo teve como objetivo identificar a existência de diferenças setoriais na previsão de risco de *default* de empresas norte-americanas de infraestrutura a partir de regressão logística com variável dependente binária.

Verificamos que a separação setorial para estimação da probabilidade de inadimplência pode contribuir para a identificação de causas específicas dessa probabilidade que estão atreladas a idiosincrasias setoriais. A variável DD mostrou que tem boa aplicabilidade para análises setoriais.

O estudo mostrou que é possível explicar a probabilidade de inadimplência de cada setor separadamente. Apesar das limitações deste estudo, principalmente em termos do pequeno número de eventos de inadimplência por setor, ele pode contribuir para a criação de novas pesquisas que levem em consideração as especificidades setoriais no cálculo do risco de inadimplência, como eventos relacionados à sazonalidade.

Outra forma de explorar esses resultados é usar a variável DD como uma variável dependente na modelagem da probabilidade de inadimplência.



Identificou-se que essa variável possui sensibilidades diferentes de acordo com cada setor.

Estudos futuros poderiam incluir a existência de variáveis mais significativas, uma vez que tal ajuste possibilitaria o aumento dos eventos de interesse. Por fim, investigar a probabilidade de inadimplência de empresas de diferentes setores de infraestrutura pode contribuir para a criação de mecanismos específicos de análise de risco corporativo de forma mais detalhada, evitando que o mau desempenho em determinados indicadores penalize empresas em setores não sensíveis a esses indicadores.

## THE BANKRUPTCY RISK IN INFRASTRUCTURE SECTORS: AN ANALYSIS FROM 2006 TO 2018

### ABSTRACT

**Purpose:** This research aims to identify the probability of default of infrastructure companies considering the sector specificities of their activities. In addition, the work seeks to identify the application of structural variables of probability of default in a model in a reduced way in order to identify the significance of its use. For this purpose, we investigated 1,520 North American companies from six different sectors linked to infrastructure.

**Originality/value:** The analyzes carried out to identify the probability of a company going bankrupt hardly consider its sectorial particularity. Although most models bring important inputs for risk assessment, most of them do not consider this sectoral view. Then, this work has as value and originality the contribution to fill this gap and identify the existence of sectorial differences in the analysis of default risk in infrastructure companies in the North American market in the period between 2006 and 2018.

**Design/methodology/approach:** The study performed a logistic regression (logit model) using 11 model variables established in calculating the probability of default. It also used the variable distance to default as an explanatory variable in order to identify its ability to explain the researched phenomenon.

**Findings:** The study identified that, in addition to the size of the companies, the distance to default variable is the only variable that can be

applied with significance in all the analyzed sectors. In addition, it was identified that companies in the oil and gas sector have less sensitivity to this variable than companies in the other sectors.

## KEYWORDS

Sectoral risk. Distance to default. Infrastructure. Merton model. Credit risk.

## REFERÊNCIAS

- Allen, L., & Saunders, A. (2002). *A survey of cyclical effects in credit risk measurement models* (Working Paper No. 126). Basel, Switzerland.
- Altman, E. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *The Journal of Finance*, 23(4), 589–609. Recuperado de <https://www.jstor.org/stable/2978933>
- Altman, E., Resti, A., & Sironi, A. (2004). Default recovery rates in credit risk modelling: A review of the literature and empirical evidence. *Economic Notes*, 33(2), 183–208.
- Altman, E. I., & Saunders, A. (1997). Credit risk measurement: Developments over the last 20 years. *Journal of Banking & Finance*, 21(11–12), 1721–1742.
- Beaver, W. (1967). Financial ratio as predictors of failure, empirical research in accounting: selected studies 1966. *Journal of Accounting Research*, 4, 71–111.
- Beaver, W. H., McNichols, M. F., & Rhie, J.-W. (2005). Have financial statements become less informative? Evidence from the ability of financial ratios to predict bankruptcy. *Review of Accounting Studies*, 10(1), 93–122.
- Bharath, S. T., & Shumway, T. (2008). Forecasting default with the Merton distance to default model. *The Review of Financial Studies*, 21(3), 1339–1369.
- Black, F., & Scholes, M. (1973). The pricing of options and corporate liabilities. *Journal of Political Economy*, 81(3), 637–654.
- Chen, P., & Wu, C. (2014). Default prediction with dynamic sectoral and macroeconomic frailties. *Journal of Banking & Finance*, 40, 211–226.
- Crosbie, P., & Bohn, J. (2003). *Modeling default risk* (Technical Report). San Francisco, CA: KMV.

- Damodaran, A. (2012). *Investment valuation: Tools and techniques for determining the value of any asset* (Vol. 666). Hoboken, NJ: John Wiley & Sons.
- Della Croce, R., & Gatti, S. (2014). Financing infrastructure: International trends. *OECD Journal: Financial Market Trends*, 2014(1), 123–138.
- Duffie, D., Eckner, A., Horel, G., & Saita, L. (2009). Frailty correlated default. *The Journal of Finance*, 64(5), 2089–2123. doi:10.1111/j.1540-6261.2009.01495.x
- Duffie, D., & Garleanu, N. (2001). Risk and valuation of collateralized debt obligations. *Financial Analysts Journal*, 57(1), 41–59.
- Duffie, D., & Lando, D. (2001). Term structures of credit spreads with incomplete accounting information. *Econometrica*, 69(3), 633–664.
- Duffie, D., Saita, L., & Wang, K. (2007). Multi-period corporate default prediction with stochastic covariates. *Journal of Financial Economics*, 83(3), 635–665.
- Escribano, A., & Maggi, M. (2019). Intersectoral default contagion: A multivariate Poisson autoregression analysis. *Economic Modelling*, 82, 376–400.
- Giesecke, K. (2004). Correlated default with incomplete information. *Journal of Banking & Finance*, 28(7), 1521–1545.
- Grimsey, D., & Lewis, M. K. (2002). Evaluating the risks of public private partnerships for infrastructure projects. *International Journal of Project Management*, 20(2), 107–118.
- Hart, O., Shleifer, A., & Vishny, R. W. (1997). The proper scope of government: Theory and an application to prisons. *The Quarterly Journal of Economics*, 112(4), 1127–1161.
- Hertzel, M. G., & Officer, M. S. (2012). Industry contagion in loan spreads. *Journal of Financial Economics*, 103(3), 493–506.
- Hillegeist, S. A., Keating, E. K., Cram, D. P., & Lundstedt, K. G. (2004). Assessing the probability of bankruptcy. *Review of Accounting Studies*, 9(1), 5–34.
- Izan, H. Y. (1984). Corporate distress in Australia. *Journal of Banking & Finance*, 8(2), 303–320.
- Jarrow, R. A., & Yu, F. (2001). Counterparty risk and the pricing of defaultable securities. *The Journal of Finance*, 56(5), 1765–1799.
- Jayasekera, R. (2018). Prediction of company failure: Past, present and promising directions for the future. *International Review of Financial Analysis*, 55, 196–208.



- Jones, S., & Hensher, D. (2008). Advances in credit risk modelling and corporate bankruptcy prediction. Cambridge, UK: Cambridge University Press.
- Jorion, P., & Zhang, G. (2009). Credit contagion from counterparty risk. *The Journal of Finance*, 64(5), 2053–2087. doi:10.1111/j.1540-6261.2009.01494.x
- Kealhofer, S. (2003). Quantifying credit risk I: Default prediction. *Financial Analysts Journal*, 59(1), 30–44.
- Kliestik, T., Misankova, M., & Kocisova, K. (2015). Calculation of distance to default. *Procedia Economics and Finance*, 23, 238–243.
- Koopman, S. J., Lucas, A., & Schwaab, B. (2012). Dynamic factor models with macro, frailty, and industry effects for US default counts: The credit crisis of 2008. *Journal of Business & Economic Statistics*, 30(4), 521–532.
- Kumari, A., & Sharma, A. K. (2017). Infrastructure financing and development: A bibliometric review. *International Journal of Critical Infrastructure Protection*, 16, 49–65.
- Lando, D., & Nielsen, M. S. (2010). Correlation in corporate defaults: Contagion or conditional independence? *Journal of Financial Intermediation*, 19(3), 355–372.
- Lane, W. R., Looney, S. W., & Wansley, J. W. (1986). An application of the Cox proportional hazards model to bank failure. *Journal of Banking & Finance*, 10(4), 511–531.
- LeClere, M. J. (2005). Time-dependent and time-invariant covariates within a proportional hazards model: A financial distress application. *Review of Accounting and Finance Working paper series Valparaiso university*. Recuperado de <https://ssrn.com/abstract=311301>.
- Lee, S. H., & Urrutia, J. L. (1996). Analysis and prediction of insolvency in the property-liability insurance industry: a comparison of logit and hazard models. *The Journal of Risk and Insurance*, 63, p. 121–130.
- Lennox, C. (1999). Identifying failing companies: A re-evaluation of the logit, probit and DA approaches. *Journal of Economics and Business*, 51(4), 347–364.
- Markowitz, H. (1952). Portfolio selection. *The Journal of Finance*, 7(1), 77–91.
- Merton, R. C. (1974). On the pricing of corporate debt: The risk structure of interest rates. *The Journal of Finance*, 29(2), 449–470.
- Mustafa, A. (1999). Public-private partnership: An alternative institutional model for implementing the private finance initiative in the provision of transport infrastructure. *The Journal of Structured Finance*, 5(1), 56–71.

- Ohlson, J. A. (1980). Financial ratios and the probabilistic prediction of bankruptcy. *Journal of Accounting Research*, 18(1), 109–131.
- Platt, H. D., & Platt, M. B. (1990). Development of a class of stable predictive variables: The case of bankruptcy prediction. *Journal of Banking & Finance*, 17(1), 31–51.
- Platt, H. D., & Platt, M. B. (1991). A note on the use of industry-relative ratios in bankruptcy prediction. *Journal of Banking & Finance*, 15(6), 1183–1194.
- Pu, X., & Zhao, X. (2012). Correlation in credit risk changes. *Journal of Banking & Finance*, 36(4), 1093–1106.
- Ruiz-Nuñez, F., & Wei, Z. (2015). *Infrastructure investment demands in emerging markets and developing economies*. Washington: The World Bank.
- Saunders, A., & Thomas, H. A. L. (1997). *Financial institutions management*. (1st ed.). New York: McGraw Hill/Irwin/Ryerson.
- Sharma, A. K., & Vohra, E. (2008). Foreign direct investment in the electricity sector: The Indian perspective. *The Electricity Journal*, 21(7), 63–79.
- Shumway, T. (2001). Forecasting bankruptcy more accurately: A simple hazard model. *The Journal of Business*, 74(1), 101–124.
- Smithson, C., & Hayt, G. (2001). Implementation of new approaches to credit portfolio management. *RMA Journal*, 84(2), 71–79.
- Soleimani, H., Golmakani, H. R., & Salimi, M. H. (2009). Markowitz-based portfolio selection with minimum transaction lots, cardinality constraints and regarding sector capitalization using genetic algorithm. *Expert Systems with Applications*, 36(3), 5058–5063.
- Taffler, R. J. (1984). Empirical models for the monitoring of UK corporations. *Journal of Banking & Finance*, 8(2), 199–227.
- Vasicek, O. A. (1984). *Credit valuation* (Technical Report). San Francisco, CA: KMV.
- Wooldridge, J. M. (2010). *Econometric analysis of cross section and panel data*. Cambridge, Massachusetts: MIT Press.
- Zhou, C. (2001). An analysis of default correlations and multiple defaults. *The Review of Financial Studies*, 14(2), 555–576.
- Zmijewski, M. E. (1984). Methodological issues related to the estimation of financial distress prediction models. *Journal of Accounting Research*, 22 (suppl.), 59–82.



## NOTAS DO AUTOR

**Vanderson A. Delapedra-Silva**, mestre pela Faculdade de Ciências e Letras, Universidade Estadual Paulista “Júlio de Mesquita Filho” (Unesp).

Vanderson A. Delapedra-Silva é agora doutorando em Finanças e Métodos Quantitativos da Faculdade de Economia, Administração, Contabilidade e Gestão de Políticas Públicas da Universidade de Brasília (UnB), e assessor I em unidade estratégica do Banco do Brasil.

Correspondências sobre este artigo devem ser enviadas para Vanderson A. Delapedra-Silva, Saun, s/n, Quadra 5, Lote B, Edifício Banco do Brasil, Asa Norte, Brasília, Distrito Federal, Brasil, CEP 70040-912.

*E-mail:* vanderson.economia@gmail.com

### CORPO EDITORIAL

**Editor-chefe**

*Gilberto Perez*

**Editor associado**

*Flavio Luiz de Moraes Barboza*

**Suporte técnico**

*Vitória Batista Santos Silva*

### PRODUÇÃO EDITORIAL

**Coordenação editorial**

*Jéssica Dametta*

**Preparação de originais**

*Carlos Villarruel*

**Revisão**

*Paula Di Sessa Vavlis*

**Diagramação**

*Emap*

**Projeto gráfico**

*Libro*