



PUC-SP

PONTIFÍCIA UNIVERSIDADE CATÓLICA DE SÃO PAULO

Flavia Braga de Souza

**Gestão do Risco de Crédito com *Score* Dinâmico para previsão de inadimplência
de Pequenas e Médias Empresas (PME)**

Mestrado em Ciências Contábeis, Controladoria e Finanças

São Paulo

2025

Flavia Braga de Souza

Gestão do Risco de Crédito com *Score* Dinâmico para previsão de inadimplência de Pequenas e Médias Empresas (PME)

Dissertação apresentada à banca examinadora da Pontifícia Universidade Católica de São Paulo, como exigência parcial para obtenção do título de MESTRE PROFISSIONAL em Ciências Contábeis, Controladoria e Finanças, sob a orientação do Prof. Dr. José Odílio dos Santos.

São Paulo

2025

Autorizo, exclusivamente para fins acadêmicos e científicos, a reprodução total ou parcial desta Dissertação de Mestrado por processos de fotocopiadoras ou eletrônicos.

Assinatura: Flavia Braga

Data: 04/09/2025

E-mail: flaviabraga1256@gmail.com

Banca Examinadora

Prof. Dr. José Odálio dos Santos

Pontifícia Universidade Católica de São Paulo - PUC-SP

Prof. Dr. José Roberto Securato

Pontifícia Universidade Católica de São Paulo - PUC-SP

Prof. Dr. João Carlos Douat

FGV EAESP - Escola de Administração de Empresas de São Paulo

AGRADECIMENTOS

Agradeço primeiramente a Deus, pela vida, saúde e pela força concedida em todos os momentos dessa caminhada.

Aos meus pais, Almir e Natalia, por serem meu alicerce, pela educação, pelos valores e pelo amor incondicional. Às minhas irmãs, Bruna e Letícia, por todo carinho, incentivo e apoio constante.

Ao meu orientador, Prof. Dr. José Odílio dos Santos, por ser um grande incentivador que acreditou em mim desde a graduação e por todo o suporte dedicado ao longo desta dissertação.

Ao meu líder no trabalho, Fabrício, por confiar em meu potencial, apoiar minhas ideias e proporcionar a autonomia necessária para meu crescimento profissional e pessoal.

Ao Prof. Dr. Fernando de Almeida Santos, coordenador do curso, pela gestão comprometida e apoio aos alunos ao longo do mestrado.

Ao Prof. Dr. José Roberto Securato, por suas valiosas contribuições que vão além da teoria, trazendo experiências de vida e mercado — marca de um verdadeiro mestre.

À Prof. Dra. Fabiana Lopes da Silva, pelos ensinamentos que foram base para este trabalho e para tantos outros futuros.

Aos colegas do mestrado, por cada troca de experiência e aprendizado ao longo dessa jornada. Em especial, à Janice, pela parceria, pelo incentivo contínuo e por compartilhar generosamente seus conhecimentos.

“A educação não transforma o mundo. A educação muda as pessoas. Pessoas transformam o mundo” (Freire, 1979, p. 84).

RESUMO

SOUZA, Flavia B D. **Gestão do Risco de Crédito com Score Dinâmico para previsão de inadimplência de Pequenas e Médias Empresas (PME)**. (Mestrado em Ciências Contábeis, Controladoria e Finanças). Pontifícia Universidade Católica de São Paulo, 2025.

O objetivo deste estudo foi desenvolver um score dinâmico para prever a inadimplência utilizando regressão logística binária aplicada, como ferramenta de monitoramento da carteira ativa de uma Sociedade de Crédito Direto voltada ao financiamento de Pequenas e Médias Empresas (PME) com garantia de recebíveis de cartão. A abordagem permite acompanhar continuamente o risco de crédito das operações já concedidas, apoiando decisões estratégicas de gestão e mitigação de inadimplência. A pesquisa utilizou uma base com 2.400 contratos ativos, com variáveis explicativas classificadas entre características estáticas e comportamentais das empresas. A variável dependente foi a situação do cliente (adimplente ou inadimplente), definida com base em atraso superior a 90 dias. O modelo proposto apresentou alta capacidade explicativa, com pseudo R^2 de Nagelkerke de 0,962, sendo estatisticamente significativo ($p < 0,001$). As variáveis mais influentes para a inadimplência foram: percentual do saldo em aberto, status baixado na Receita Federal e classificação “Crítico” no indicador farol de pagamento. Os resultados demonstram que o uso combinado de variáveis comportamentais e cadastrais permite maior assertividade na previsão de risco, contribuindo para uma gestão mais eficaz da carteira de crédito. A metodologia proposta é aplicável ao monitoramento contínuo de risco e à construção de um *score* dinâmico, com potencial para aprimorar políticas de crédito.

Palavras-chave: risco de crédito; inadimplência; pme; regressão logística binária, *score* dinâmico.

ABSTRACT

SOUZA, Flavia B D. **Credit Risk Management with Dynamic Scoring for Default Prediction of Small and Medium-Sized Enterprises (SME)**. (Mestrado em Ciências Contábeis, Controladoria e Finanças). Pontifícia Universidade Católica de São Paulo, 2025.

This study aimed to develop a dynamic credit risk score to predict default using binary logistic regression, serving as a monitoring tool for the active portfolio of a Direct Credit Society focused on financing Small and Medium Enterprises (SME) backed by card receivables. The approach enables continuous tracking of credit risk in already granted operations, supporting strategic management and default mitigation decisions. The analysis was conducted on a dataset of 2,400 active contracts, with explanatory variables categorized as static or behavioral characteristics of the companies. The dependent variable was client status (performing or defaulted), defined by arrears exceeding 90 days. The proposed model demonstrated high explanatory power, with a Nagelkerke pseudo R^2 of 0.962 and statistical significance ($p < 0.001$). The most influential predictors of default were the percentage of outstanding balance, deregistered status with the Federal Revenue Service, and a “Critical” rating in the payment alert indicator. Results indicate that combining behavioral and cadastral variables improves predictive accuracy, contributing to more effective credit portfolio management. The proposed methodology is suitable for continuous risk monitoring and dynamic score development, with potential to enhance credit policy frameworks.

Keywords: credit risk; default; sme; binary logistic regression; dynamic scoring.

LISTA DE QUADROS

| | |
|--|----|
| Quadro 1 - Pesquisas sobre o tema publicadas no Brasil | 29 |
| Quadro 2 - Pesquisas sobre o tema publicadas no exterior | 31 |
| Quadro 3 - Variáveis independentes testadas | 37 |

LISTA DE TABELAS

| | |
|---|----|
| Tabela 1 - Variáveis removidas pelo teste de multicolinearidade | 40 |
| Tabela 2 - Resultados do Teste de Multicolinearidade (VIF) | 40 |
| Tabela 3 - Seleção inicial de variáveis com base nos valores de p | 42 |
| Tabela 4 - Resumo de processamento | 44 |
| Tabela 5 - Tabela de classificação – Bloco 0 | 44 |
| Tabela 6 - Teste de Omnibus do Modelo de Coeficientes – Bloco 1 | 45 |
| Tabela 7 - Resumo do Modelo | 45 |
| Tabela 8 - Teste de Hosmer e Lemeshow..... | 46 |
| Tabela 9 - Tabela de classificação – Bloco 1 | 46 |
| Tabela 10 - Coeficientes de regressão e razão de chance..... | 47 |
| Tabela 11 - Perfis hipotéticos de clientes | 52 |

LISTA DE FIGURAS

| | |
|---|----|
| Figura 1 - Histórico de abertura e fechamento de empresas (2014 a 2024) | 20 |
| Figura 2 - Evolução anual do crédito bancário – Por porte de empresa..... | 20 |
| Figura 3 - Ativos Problemáticos – Por porte de empresa | 21 |

LISTA DE ABREVIATURAS E SIGLAS

| | |
|----------|---|
| BACEN | Banco Central do Brasil |
| BIS | Bank for International Settlements |
| CEPAL | Comissão Econômica para a América Latina e o Caribe |
| CNDL | Confederação Nacional de Dirigentes Lojistas |
| CNPJ | Cadastro Nacional da Pessoa Jurídica |
| CNPJB | CNPJ Baixado na Receita Federal |
| EDT | Endividamento Total |
| FAT | Faturamento de Recebíveis |
| FPG | Farol de Pagamento |
| H0 | Hipótese nula |
| H1 | Hipótese alternativa |
| IASB | International Accounting Standards Board |
| IBM SPSS | International Business Machines Statistical Package for the Social Sciences (pacote estatístico usado para análise de dados) |
| IFRS | International Financial Reporting Standards |
| IRB | Internal Ratings-Based |
| LGD | Loss Given Default (Perda Dada a Inadimplência) |
| LOC | Localização Geográfica |
| Moody's | (Nome da agência de rating; geralmente não se usa sigla) |
| PCDC | Percentual de Dias em Crítico |
| PCEA | Percentual de Dias em Atraso |
| PCFE | Percentual de Dias Fora do Esperado |
| PCSA | Percentual do Saldo em Aberto |
| PD | Probability of Default (Probabilidade de Inadimplência) |
| PIB | Produto Interno Bruto Nacional |
| PMEs | Pequenas e Médias Empresas |
| PPP | Proporção de Parcelas Pagas |
| PZC | Prazo Contratual |
| QTC | Quantidade de Comunicações |
| QTDA | Quantidade de Dias de Atraso |
| QTDSA | Quantidade de Dias sem Acesso à Plataforma |
| QTIFS | Quantidade de Instituições Financeiras |

| | |
|--------------|--|
| QTPA | Quantidade de Parcelas Atrasadas |
| QTR | Quantidade de Restritivos |
| RTC | Rating de Concessão |
| S.E. ou E.P. | Erro padrão (Standard Error / Erro Padrão) |
| SCD | Sociedade de Crédito Direto |
| SDA | Setor de Atuação |
| SEBRAE | Serviço Brasileiro de Apoio às Micro e Pequenas Empresas |
| SPC Brasil | Serviço de Proteção ao Crédito Brasil |
| SPSS | Statistical Package for the Social Sciences (pacote estatístico) |
| TEMPC | Tempo de Concessão |
| TEMPF | Tempo de Fundação da Empresa |
| TKM | Ticket Médio |
| VARFR | Varição no Faturamento de Recebíveis |
| VARQT | Varição na Quantidade de Transações na Conta |
| VIF | Fator de Inflação da Variância (Variance Inflation Factor) |
| VLCC | Valor do Crédito Concedido |
| VLPM | Valor da Parcela Mensal |
| VLSD | Valor do Saldo Devedor |

LISTA DE SÍMBOLOS

| | |
|---------------------|--|
| χ^2 | Qui-quadrado (chi-square) |
| R^2 | Coefficiente de determinação |
| R^2 de Nagelkerke | Pseudo R^2 de Nagelkerke (medida ajustada para modelos logísticos) |

SUMÁRIO

| | | |
|----------------|--|-----------|
| 1 | INTRODUÇÃO | 15 |
| 1.1 | Objetivo | 15 |
| 1.2 | Justificativas | 15 |
| 1.3 | Problematização..... | 16 |
| 1.4 | Metodologia e hipótese da pesquisa | 16 |
| 1.5 | Estrutura | 17 |
| 2 | FUNDAMENTAÇÃO TEÓRICA..... | 19 |
| 2.1 | Pequenas e Médias Empresas | 19 |
| 2.2 | Risco de Crédito e Inadimplência | 22 |
| 2.3 | Metodologias de Avaliação do Risco de Crédito..... | 24 |
| <i>2.3.1</i> | <i>Credit Scoring.....</i> | <i>24</i> |
| <i>2.3.2</i> | <i>Ratings de Crédito</i> | <i>25</i> |
| <i>2.3.3</i> | <i>Modelos Preditivos de Insolvência.....</i> | <i>25</i> |
| <i>2.3.4</i> | <i>Modelos Internos (IRB) para PMEs</i> | <i>26</i> |
| 2.4 | Informações analisadas para mensurar o risco de crédito | 26 |
| 2.5 | Garantias de Crédito com Enfoque em Recebíveis de Cartão | 27 |
| 2.6 | Pesquisas sobre o tema central da pesquisa publicadas no Brasil | 29 |
| 2.7 | Pesquisas sobre o tema central da pesquisa publicadas no exterior | 31 |
| 3 | METODOLOGIA..... | 33 |
| 3.1 | Técnica de Regressão Logística | 33 |
| 3.2 | Descrição da pesquisa..... | 35 |
| <i>3.2.1</i> | <i>Critérios de Seleção da Amostra.....</i> | <i>35</i> |
| <i>3.2.2</i> | <i>Coleta e Tratamento dos Dados.....</i> | <i>36</i> |
| <i>3.2.3</i> | <i>Construção da Data de Corte</i> | <i>36</i> |
| <i>3.2.4</i> | <i>Definição da Variável Dependente.....</i> | <i>36</i> |
| <i>3.2.5</i> | <i>Seleção das Variáveis Independentes</i> | <i>37</i> |
| <i>3.2.5.1</i> | <i>Teste de Multicolinearidade</i> | <i>39</i> |
| <i>3.2.6</i> | <i>Técnica Estatística Aplicada.....</i> | <i>41</i> |
| 4 | RESULTADOS E ANÁLISE..... | 42 |
| 4.1 | Resultados dos Testes Estatísticos..... | 42 |
| 4.2 | Resumo do Processamento dos dados..... | 44 |

| | | |
|-------------|---|-----------|
| 4.3 | Resultado Bloco 0..... | 44 |
| 4.4 | Teste de Omnibus do Modelo de Coeficientes..... | 45 |
| 4.5 | R² de Nagelkerke..... | 45 |
| 4.6 | Teste de Hosmer e Lemeshow..... | 46 |
| 4.7 | Resultado Bloco 1..... | 46 |
| 4.8 | Teste de Wald..... | 47 |
| 4.9 | Análise dos Coeficientes | 48 |
| 4.9.1 | Tempo de fundação da empresa | 48 |
| 4.9.2 | CNPJ Baixado na Receita Federal | 49 |
| 4.9.3 | Prazo contratual | 49 |
| 4.9.4 | Percentual do Saldo em Aberto | 49 |
| 4.9.5 | Percentual de Dias em Atraso..... | 50 |
| 4.9.6 | Ticket Médio..... | 50 |
| 4.9.7 | Farol de Pagamento Crítico e Fora do Esperado | 50 |
| 4.9.8 | Quantidade de dias em Atraso | 51 |
| 4.9.9 | Quantidade de Dias sem Acesso à Plataforma | 51 |
| 4.9.10 | Variação na Quantidade de Transações na Conta..... | 51 |
| 4.10 | Aplicabilidade do modelo em situações hipotéticas..... | 51 |
| 5 | CONSIDERAÇÕES FINAIS..... | 55 |
| | REFERÊNCIAS | 57 |

1 INTRODUÇÃO

O acesso ao crédito é um dos pilares fundamentais para o desenvolvimento e sustentabilidade das Pequenas e Médias Empresas (PMEs), que representam uma parcela significativa da geração de empregos e da movimentação econômica no Brasil. Com o avanço da tecnologia, novas formas de concessão de crédito têm emergido, muitas delas baseadas em dados e automação.

Entretanto, apesar da agilidade na concessão, o risco de inadimplência continua sendo um desafio central na gestão da carteira de crédito. Monitorar o comportamento dos clientes após a liberação do empréstimo torna-se uma prática cada vez mais necessária para evitar perdas, antecipar situações de risco e permitir ações preventivas de cobrança e renegociação. Nesse contexto, surge a demanda por ferramentas de acompanhamento contínuo da carteira, com destaque para os *scores* dinâmicos de crédito, que atualizam periodicamente a avaliação de risco com base em dados comportamentais e financeiros mais recentes.

1.1 Objetivo

O presente trabalho tem como objetivo desenvolver um modelo preditivo, com base em regressão logística binomial, capaz de construir um *score* dinâmico que estime, de forma recorrente, a probabilidade de inadimplência dos clientes de uma Sociedade de Crédito Direto (SCD) voltada às PMEs. O modelo foi alimentado por variáveis estáticas (cadastrais e contratuais) e dinâmicas (comportamentais e financeiras), permitindo o monitoramento contínuo da carteira ativa e subsidiando a tomada de decisão pelas áreas de risco e cobrança. Essa abordagem possibilita acompanhar de forma sistemática o risco de crédito das operações já concedidas, apoiando a gestão estratégica e a mitigação de inadimplência.

A pesquisa busca aprender com os clientes que já apresentaram problemas de inadimplência, identificando os fatores que antecedem o *default*, atraso superior a 90 dias, com vistas a apoiar decisões de crédito e, sobretudo, orientar ações preventivas para mitigar futuros casos de inadimplência.

1.2 Justificativas

A motivação para a realização desta pesquisa decorre da experiência da autora na gestão e acompanhamento de carteiras de crédito, aliada à necessidade de ferramentas robustas que

permitam prever e prevenir a inadimplência com base em um entendimento aprofundado do comportamento dos clientes inadimplentes.

A importância deste estudo reside na possibilidade de gerar um instrumento prático de acompanhamento e gestão da carteira de crédito, permitindo à instituição antecipar comportamentos de risco e agir de maneira proativa, com foco na redução da inadimplência e no aumento da sustentabilidade operacional.

1.3 Problematização

Grande parte dos modelos de crédito utilizados no momento da concessão são estáticos, baseando-se em informações cadastrais e histórico passado, sem considerar a evolução comportamental e financeira do cliente ao longo do tempo. Essa limitação dificulta a identificação precoce de sinais de deterioração do risco, o que reduz a capacidade de resposta da instituição frente a potenciais casos de inadimplência.

Na prática, a ausência de um modelo dinâmico de *score* dificulta o monitoramento da carteira ativa, tornando as ações de cobrança mais reativas do que preventivas. Isso resulta em um aumento da inadimplência, perdas financeiras, necessidade de provisionamento e impactos na sustentabilidade da operação.

Diante desse cenário, surge a seguinte problemática central: Como desenvolver um modelo dinâmico que permita à SCD acompanhar, de forma contínua e automatizada, a evolução do risco de inadimplência de seus clientes de crédito já ativos?

A partir disso, a pesquisa visa não apenas entender os determinantes da inadimplência, mas também oferecer uma base para a criação de políticas preventivas que possam reduzir a ocorrência de *default* no futuro.

1.4 Metodologia e hipótese da pesquisa

Este estudo propõe o desenvolvimento de um modelo de *score* dinâmico para monitoramento da inadimplência de clientes de crédito ativos em uma SCD voltada para PMEs.

A pesquisa adota uma abordagem quantitativa com aplicação de regressão logística binomial para prever a inadimplência de clientes ativos de uma SCD voltada a PMEs. A base de dados contempla contratos ativos em 31/03/2025, com ao menos 120 dias desde a concessão, todos garantidos por recebíveis de cartões (crédito/débito).

Foram excluídos contratos liquidados, renegociados, com análise manual ou gerados para testes. A variável dependente foi construída com base em atraso superior a 90 dias, respeitando a lógica temporal por meio de uma data de corte anterior ao evento de inadimplência.

As variáveis explicativas — cadastrais, financeiras, contratuais e comportamentais — foram tratadas estatisticamente e selecionadas com base na literatura e experiência prática. O modelo foi desenvolvido no IBM SPSS *Statistics*, visando apoiar ações preventivas de cobrança e gestão de risco.

Para guiar a análise, foram formuladas as seguintes hipóteses:

- H0: Variáveis cadastrais, contratuais e relacionadas ao comportamento financeiro e de interações recentes da empresa não têm efeito estatisticamente significativo na predição de inadimplência. Nesse caso presume-se que não devem ser utilizadas como indicadores de risco de crédito para prever a ocorrência do default.
- H1: Variáveis cadastrais, contratuais e relacionadas ao comportamento financeiro e de interações recentes da empresa têm efeito estatisticamente significativo na predição de inadimplência. Nesse caso presume-se que devem ser utilizadas como indicadores de risco de crédito para prever a ocorrência do default.

1.5 Estrutura

O trabalho está organizado da seguinte forma:

Capítulo 1 – Introdução: Apresentação do contexto, objetivos, justificativas, problematização e estrutura da dissertação.

Capítulo 2 – Referencial Teórico: Discussão sobre risco de crédito, inadimplência, modelos preditivos e informações analisadas para mensurar o risco de crédito.

Capítulo 3 – Procedimentos Metodológicos: Descrição detalhada da abordagem adotada, incluindo definição da amostra, fontes de dados, técnicas de análise estatística e ferramentas utilizadas.

Capítulo 4 – Resultados e Análises: Apresentação e análise dos resultados obtidos a partir da aplicação da regressão logística, com destaque para as variáveis mais relevantes para a previsão da inadimplência.

Capítulo 5 – Considerações Finais: Discussão dos principais achados da pesquisa, suas implicações para a gestão de crédito, limitações do estudo e sugestões para futuras pesquisas.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Pequenas e Médias Empresas

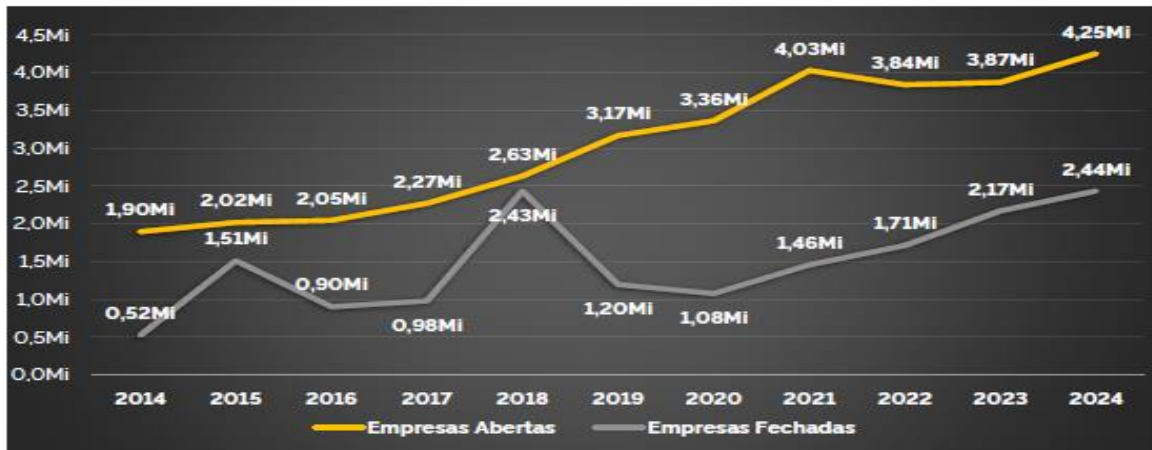
As Pequenas e Médias Empresas (PMEs) constituem um dos pilares fundamentais da economia brasileira, desempenhando um papel estratégico no desenvolvimento socioeconômico do país. No Brasil, instituições como o Serviço Brasileiro de Apoio às Micro e Pequenas Empresas (SEBRAE) e a Lei Geral da Micro e Pequena Empresa (Lei Complementar nº 123/2006) estabelecem diretrizes para sua classificação, considerando principalmente o faturamento bruto anual e o setor de atividade (comércio, serviços ou indústria). Nesse contexto, são consideradas PMEs as empresas com faturamento anual de até R\$ 4.800.000,00.

A relevância das PMEs para o cenário brasileiro transcende a mera contribuição econômica, pois atuam como agentes de diversificação econômica, estando presentes em praticamente todos os setores produtivos. Essa pulverização de atividades reduz a dependência de um único segmento e torna a economia mais resiliente a choques externos.

Segundo o Mapa de Empresas divulgado pelo Governo Federal (2025), no terceiro quadrimestre de 2024 o país contava com 22.004.843 empresas ativas, das quais 93,4% eram microempresas ou empresas de pequeno porte. Além disso, as PMEs respondem por 26,5% do PIB nacional.

Os três primeiros meses de 2025 registraram crescimento significativo na abertura de pequenos negócios. De acordo com levantamento do SEBRAE, foram criados 1.407.010 novos CNPJs até março, sendo 78% deles referentes a microempreendedores individuais (MEIs). Esse movimento confirma a tendência de expansão no empreendedorismo. A Figura 1 apresenta o histórico de abertura e fechamento de empresas no Brasil ao longo dos últimos dez anos.

Figura 1 - Histórico de abertura e fechamento de empresas (2014 a 2024)

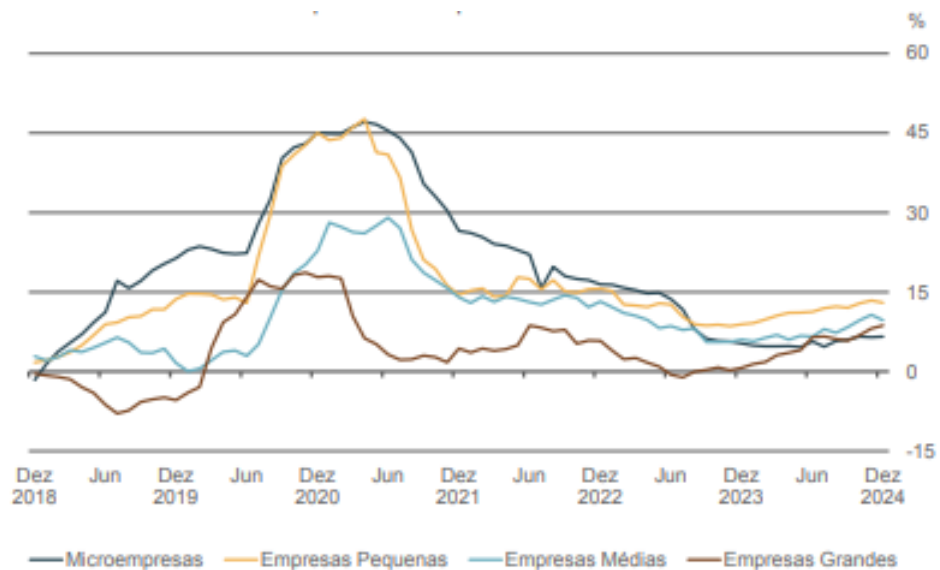


Fonte: Mapa de empresas (Governo Federal, 2025).

Em 2024, foram abertas 4.254.903 empresas no país, o que representa um aumento de 9,8% em relação a 2023. Apesar do fechamento de 2.436.190 empresas, o saldo positivo foi de 1.818.713, o que equivale a um crescimento de 6,9% frente ao ano anterior. Os dados históricos reforçam a tendência de crescimento contínuo da atividade empreendedora no país.

Para manter suas operações, expandir e inovar, as PMEs têm uma necessidade intrínseca de acesso ao crédito, uma vez que muitas delas não dispõem de capital próprio suficiente para sustentar o crescimento ou enfrentar oscilações econômicas. O acesso a linhas de crédito adequadas permite que essas empresas invistam em tecnologia, ampliem a produtividade e aumentem sua competitividade no mercado. A Figura 2 ilustra a evolução do crédito bancário, evidenciando uma redução entre 2021 e 2024 em todos os portes de empresa.

Figura 2 - Evolução anual do crédito bancário – Por porte de empresa



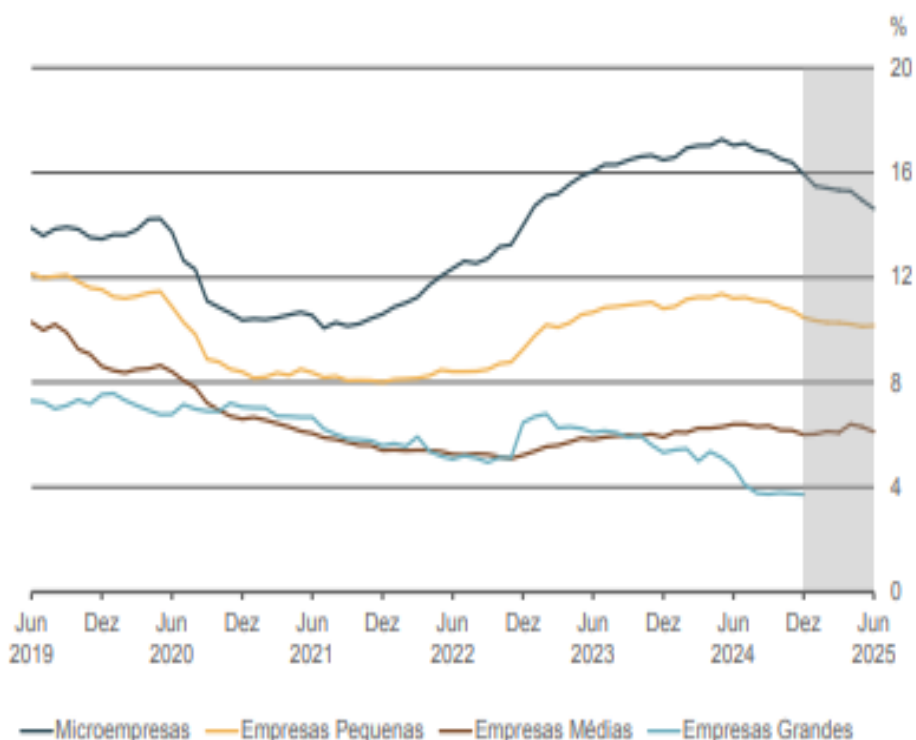
Fonte: Relatório de Estabilidade Financeiras BACEN (2025).

Embora promissor, o segmento de PMEs ainda enfrenta obstáculos significativos. Conforme dados da Serasa Experian (2025), no primeiro trimestre deste ano cerca de 6,3 milhões de PMEs estavam inadimplentes — o maior número já registrado em termos absolutos. Contudo, esse volume permanece abaixo da média histórica quando analisado proporcionalmente ao total de empresas ativas. As informações fazem parte do boletim Empreender Brasil: Inteligência de Mercado para PMEs, divulgado trimestralmente.

Apesar dos recordes recentes, o crescimento da inadimplência entre micro e pequenas empresas segue em ritmo moderado: em abril de 2024, a taxa anual era de 3,4%, abaixo da média histórica de 4,7% para o período de 2016 a 2023.

Ainda segundo o Relatório de Estabilidade Financeira do Banco Central do Brasil (2025), as PMEs concentram o maior volume de ativos problemáticos — caracterizados por atrasos superiores a 90 dias ou por exposições de crédito com recuperação incerta —, o que destaca o nível de inadimplência dessas empresas em comparação com as de maior porte. A Figura 3 a seguir ilustra esse cenário, apresentando a distribuição dos ativos problemáticos por porte de empresa.

Figura 3 - Ativos Problemáticos – Por porte de empresa



Fonte: Relatório de Estabilidade Financeiras BACEN (2025).

Os dados reforçam a importância de que instituições financeiras adotem uma gestão ativa e criteriosa de suas carteiras de crédito destinadas às PMEs. Diante do volume

significativo de ativos problemáticos nesse segmento, torna-se essencial implementar mecanismos eficazes de avaliação de risco, monitoramento contínuo e estratégias de recuperação de crédito. Além de reduzir perdas e preservar a sustentabilidade das operações bancárias, uma gestão de crédito bem estruturada permite oferecer produtos financeiros mais adequados ao perfil e às necessidades dessas empresas. Ao entender melhor os ciclos de negócio e as vulnerabilidades das PMEs, as instituições financeiras podem contribuir para sua inclusão financeira, fomentar o empreendedorismo e impulsionar o crescimento econômico com responsabilidade.

2.2 Risco de Crédito e Inadimplência

O crédito desempenha papel essencial no crescimento econômico, ao viabilizar o adiantamento de recursos para consumo, investimento e expansão das atividades produtivas. Segundo Silva (2009), sua essência está na confiança do credor quanto à capacidade de pagamento do devedor, sendo, portanto, um instrumento sensível às condições econômicas e institucionais. O acesso ao crédito é determinante para a sobrevivência e o crescimento das PMEs, ao permitir investimentos em inovação e capital de giro (Comissão Econômica para a América Latina e o Caribe (CEPAL, 2017). No entanto, obstáculos como a exigência de garantias, a informalidade contábil e a ausência de histórico bancário dificultam a inserção dessas empresas no mercado de crédito tradicional.

A relação entre crédito e crescimento, contudo, não ocorre sem riscos. Conforme observado por Kasznar (2009), o crédito pode impulsionar o desenvolvimento, mas também gerar instabilidade se mal direcionado ou mal monitorado. A McKinsey & Company (2021) observa que, embora o crédito a PMEs tenha crescido no Brasil nos últimos anos, a qualidade dos dados disponíveis e os custos operacionais ainda limitam a eficiência das decisões de crédito nesse segmento.

No contexto do sistema financeiro, destaca-se o risco de crédito como uma das principais exposições assumidas pelas instituições que operam com crédito, sendo esse risco caracterizado pela possibilidade de perdas financeiras caso o tomador não honre seus compromissos. De acordo com Chang *et al.* (2008), o domínio do risco de crédito é essencial para a gestão eficiente de carteiras ativas, pois a inadimplência impacta diretamente a rentabilidade e a continuidade das instituições credoras. Como observado por Assaf Neto (2012), o risco total de uma operação de crédito pode ser decomposto em risco sistemático —

relacionado a fatores macroeconômicos como taxa de juros, inflação e política monetária — e risco não sistemático, atrelado às condições específicas do cliente e à sua gestão empresarial.

A literatura destaca que toda operação de crédito carrega consigo a possibilidade de inadimplência, e que os gestores financeiros devem ser capazes de identificá-la e quantificá-la previamente. Securato e Famá (1997) ressaltam que, na concessão do crédito, é preciso considerar que o descumprimento contratual impacta diretamente os resultados e a saúde financeira do credor. Em linha semelhante, Kavussanos e Tsouknidis (2016) definem o crédito como a colocação de um valor à disposição do cliente, mediante compromisso de devolução futura, o que implica, por si só, a existência de risco.

A inadimplência, por sua vez, corresponde ao não cumprimento das obrigações financeiras assumidas, geralmente por atraso no pagamento. Embora sua definição possa variar entre instituições, o Banco Central do Brasil (BACEN) considera inadimplente o cliente que apresenta atraso superior a 90 dias em seus compromissos (BACEN, 2023). Para Houaiss (2001), inadimplência representa, de forma geral, a falha no cumprimento de uma obrigação pactuada.

Dessa forma, é fundamental distinguir os conceitos de *delinquency* e *default*, conforme definidos nas diretrizes de Basileia e nas normas contábeis internacionais. Enquanto *delinquency* representa qualquer atraso nos pagamentos — mesmo que pequeno —, *default* é caracterizado por atraso superior a 90 dias ou pela ocorrência de eventos qualitativos que indiquem incapacidade objetiva de pagamento, como insolvência declarada, falência ou renegociação forçada do contrato (Bank for International Settlements [BIS], 2006; International Accounting Standards Board [IASB], 2014).

Os fatores que levam à inadimplência são múltiplos e frequentemente relacionados ao ambiente econômico. Costa (2016) observa que a deterioração das condições macroeconômicas, como inflação, elevação das taxas de juros e desemprego, tende a aumentar a inadimplência, sobretudo entre pessoas físicas e microempresas. Oliveira *et al.* (2015) reforçam que a inadimplência cresce em períodos de instabilidade, quando a capacidade de pagamento é reduzida por choques externos. No âmbito das *fintechs* e das SCDs, Caldas (2020) destaca que a inadimplência representa um desafio ainda maior, dada a agilidade na concessão de crédito e a estrutura mais enxuta de cobrança.

Em fevereiro de 2025, cerca de 41,5% da população adulta brasileira apresentava dívidas em atraso, totalizando 68,76 milhões de inadimplentes. Esse índice representa um aumento de 3,22% em comparação ao mesmo período do ano anterior, refletindo o impacto de fatores como juros elevados, inflação sobre alimentos e dificuldades de acesso ao crédito

(Confederação Nacional de Dirigentes Lojistas [CNDL] & Serviço de Proteção ao Crédito [SPC Brasil], 2025).

Segundo dados do CNDL, o perfil dos inadimplentes concentra-se na faixa etária de 30 a 39 anos, correspondendo a 23,81% do público negativado. Observa-se ainda uma ligeira predominância do público feminino (51%) e significativa participação do setor bancário, responsável por 66,5% dos débitos, com valor médio de R\$ 4.650 por consumidor, distribuído em aproximadamente dois credores.

Em relação à composição das dívidas, 43,9% não ultrapassa R\$ 1.000, evidenciando a relevância dos débitos de menor valor no estoque de inadimplência. Também se verifica um aumento expressivo no contingente de consumidores com atrasos entre três e quatro anos, indicando dificuldades persistentes de regularização financeira.

Nesse contexto, torna-se evidente que compreender os mecanismos que explicam a inadimplência e os fatores de risco envolvidos na concessão de crédito é essencial para a construção de modelos preditivos eficazes e para a mitigação de perdas no sistema financeiro.

2.3 Metodologias de Avaliação do Risco de Crédito

A avaliação do risco de crédito é um processo fundamental para as instituições financeiras, permitindo identificar a probabilidade de inadimplência dos tomadores e mitigar riscos relacionados à concessão de crédito. Diversas metodologias foram desenvolvidas para mensurar esse risco, combinando técnicas estatísticas clássicas, modelos internos, métodos preditivos modernos e abordagens baseadas em inteligência artificial.

2.3.1 *Credit Scoring*

Uma das metodologias mais amplamente adotadas é o *credit scoring*, que atribui uma pontuação ao cliente com base em variáveis como histórico de pagamento, capacidade de renda e perfil financeiro. Esse modelo permite classificar o tomador de crédito de acordo com o risco de inadimplência, auxiliando no processo decisório. Segundo Führt *et al.* (2022), o uso da regressão logística tem se mostrado eficaz na construção desses modelos. De forma complementar, Provenzano *et al.* (2020) demonstram que o uso de técnicas mais avançadas, como *gradient boosting machines*, aumenta a acurácia na previsão de inadimplência. No entanto, Bücken *et al.* (2020) alertam para a importância de garantir transparência e explicabilidade nos modelos baseados em aprendizado de máquina, propondo *frameworks* que aumentam sua interpretabilidade.

Essa abordagem também é destacada por Santos e Famá (2007), que apontam o *credit scoring* como um dos métodos estatísticos mais utilizados para mensurar o risco de crédito, classificando os clientes a partir de dados cadastrais, patrimoniais, financeiros e de idoneidade. Essa ordenação permite às instituições identificarem com maior precisão os perfis de risco entre os solicitantes de crédito.

Além disso, Dahooie, Gharacheh e Marjani (2021) observam que o *credit scoring* representa uma tentativa de equilibrar a necessidade dos tomadores por crédito e o risco inerente assumido pelas instituições. A crescente digitalização e o avanço dos dados alternativos também ampliaram o escopo dessas análises, especialmente no setor de *fintechs* e crédito para PMEs.

2.3.2 Ratings de Crédito

Outra ferramenta amplamente utilizada são os *ratings* de crédito, atribuídos por agências especializadas como Moody's e Standard & Poor's. Esses *ratings* refletem a capacidade de pagamento das empresas, baseando-se em uma análise extensa de sua situação econômica e financeira. Embora eficientes, esse processo é custoso e moroso, exigindo conhecimento técnico especializado (Hajek & Michalak, 2013; Huang, Chen & Wang, 2004).

Estudos recentes como o de Golbayani *et al.* (2020) sugerem que técnicas de aprendizado de máquina podem oferecer maior precisão na previsão de *ratings*, tornando o processo mais ágil e confiável. De forma semelhante, Albanesi e Vamossy (2019) propõem modelos baseados em *deep learning* que superam abordagens tradicionais em termos de desempenho na previsão de inadimplência.

2.3.3 Modelos Preditivos de Insolvência

Os modelos de previsão de insolvência também desempenham papel importante na gestão do risco de crédito, ao estimarem a probabilidade de falência de uma empresa com base em indicadores financeiros e operacionais. Selau e Ribeiro (2008) propuseram uma sistemática que combina análise discriminante, redes neurais e regressão logística para essa finalidade. Oliveira *et al.* (2015), por sua vez, aplicaram modelos de vetores autorregressivos para analisar como choques macroeconômicos impactam a inadimplência bancária em cenários de estresse.

Akkoç (2012) destaca que técnicas como máquinas de vetor de suporte e redes neurais artificiais contribuem para melhorar a capacidade preditiva desses modelos. Kozeny (2015) acrescenta que algoritmos genéticos podem ser usados como alternativa robusta para seleção de variáveis em cenários de alta complexidade.

2.3.4 Modelos Internos (IRB) para PMEs

Com o avanço da regulação prudencial, modelos internos baseados na abordagem *Internal Ratings-Based* (IRB) têm sido incorporados por instituições financeiras para estimar parâmetros como a probabilidade de inadimplência (PD), perda em caso de inadimplência (LGD) e exposição no momento da inadimplência (EAD). Esses modelos permitem uma avaliação mais granular do risco de crédito, considerando características específicas do cliente e da operação, o que se mostra particularmente relevante para pequenas e médias empresas (PMEs), cujo perfil de risco tende a ser mais heterogêneo do que o de grandes corporações.

Por outro lado, para PMEs, esses modelos são desafiadores devido à menor disponibilidade de dados e maior heterogeneidade, exigindo abordagens híbridas que combinam estatística e machine learning.

Roggi e Giannozzi (2013) analisaram a construção de ratings para pequenas e médias empresas (PMEs) e identificaram que variáveis não financeiras também contribuem significativamente para a acurácia do rating. Já Cardoso e Lima (2024) destacam a aplicação desses modelos em operações de crédito corporativo, enfatizando a importância da personalização das análises conforme o perfil da instituição e do cliente.

Além disso, Schiozer e Yoshida (2020) apontam que, no contexto de PMEs, a incorporação de dados alternativos como fluxo de clientes em lojas físicas ou tráfego nos canais digitais pode refinar significativamente os modelos de avaliação, agregando dimensões comportamentais ao risco de crédito.

Modelos quantitativos com variáveis dependentes dicotômicas — como os utilizados por Gross e Souleles (2002) na aplicação do modelo *probit* para analisar inadimplência em cartões de crédito — continuam sendo amplamente empregados. Essas abordagens são especialmente relevantes em estudos aplicados e contextos com grandes bases de dados. Como enfatizado por Gonçalves, Gouvêa e Mantovani (2015), tais modelos são ferramentas indispensáveis para classificar clientes entre “bons” e “maus” pagadores, otimizando a gestão de risco das instituições.

2.4 Informações analisadas para mensurar o risco de crédito

A avaliação do risco de crédito envolve a análise de diversas informações do tomador. Selau e Ribeiro (2008) propõem uma sistemática para a construção de modelos de previsão de risco de crédito, utilizando técnicas estatísticas como análise discriminante, regressão logística e redes neurais. O estudo demonstrou que a combinação de variáveis cadastrais, histórico de

pagamento e informações financeiras pode gerar modelos eficazes para prever o risco de inadimplência.

Führ *et al.* (2022) enfatizam a importância de variáveis não contábeis, como comportamento de pagamento e relacionamento com fornecedores, na construção de modelos preditivos. Complementando essa ideia, Fuster *et al.* (2019) defende que o uso de dados alternativos, como informações de redes sociais e comportamento transacional, tem crescido, principalmente em instituições financeiras digitais.

Björkegren e Grissen (2017) demonstram que dados de uso de telefone celular podem ser utilizados para prever a capacidade de pagamento de indivíduos sem histórico de crédito formal. Essa abordagem representa um avanço importante na inclusão financeira, utilizando informações digitais para avaliação de risco.

Além disso, indicadores macroeconômicos são incorporados para capturar o risco sistêmico e a influência do ambiente econômico sobre a capacidade de pagamento (Louzis *et al.*, 2015). A inclusão de variáveis como taxas de desemprego, inflação e políticas monetárias permite um ajuste mais preciso dos modelos em cenários econômicos variados.

Em suma, diversas informações são analisadas para mensurar esse o risco de crédito, abrangendo tanto dados tradicionais quanto alternativas inovadoras.

Portanto, a mensuração do risco de crédito envolve a análise integrada de informações tradicionais, como dados cadastrais e financeiros, aliada a variáveis inovadoras e contexto macroeconômico, permitindo maior precisão e abrangência na avaliação do perfil dos tomadores. Essa combinação é essencial para o desenvolvimento de modelos preditivos robustos e eficazes, atendendo às demandas das instituições financeiras modernas.

2.5 Garantias de Crédito com Enfoque em Recebíveis de Cartão

As garantias desempenham papel essencial na mitigação do risco de crédito, especialmente em operações envolvendo PMEs, que frequentemente enfrentam dificuldades em oferecer garantias tradicionais. Dentre as modalidades emergentes, o uso de recebíveis de cartões como garantia tem ganhado protagonismo no contexto regulatório e operacional brasileiro.

A Resolução nº 4.734/2019, emitida pelo BACEN, estabelece diretrizes para a formalização de operações de crédito com garantia de recebíveis oriundos de arranjos de pagamento, como cartões de crédito e débito. Essa norma impôs maior padronização e segurança jurídica na utilização de tais ativos como garantia, ao exigir a constituição de

gravame eletrônico e o registro da operação em entidades autorizadas pelo BACEN. Complementarmente, a Circular nº 3.952/2019 regulamenta os procedimentos operacionais e de registro, reforçando a exigência de que as instituições financeiras consultem as bases de dados das registradoras antes da contratação de qualquer operação garantida por recebíveis.

Essas mudanças visam mitigar práticas de cessão múltipla e sobreposição de garantias, trazendo maior transparência e previsibilidade para as partes envolvidas na concessão de crédito (Banco Central do Brasil, 2019). Na prática, a nova regulação fortalece o ambiente para o uso dos recebíveis como ativos garantidores.

No âmbito acadêmico, estudos como o de Machado e Ribeiro (2018) destacam a crescente utilização da antecipação de recebíveis por empresas que buscam capital de giro. Os autores observam que o uso de recebíveis, sobretudo, os vinculados a operações com cartões, tem se mostrado eficaz na redução da inadimplência e na melhoria da liquidez das empresas.

Conforme abordado pela Nuclea (2025), registradora de recebíveis de cartões, a utilização desses recebíveis como garantia tem também o potencial de aprimorar o monitoramento do risco, uma vez que permite ao credor acesso a informações mais granulares e automatizadas sobre os fluxos financeiros futuros da empresa tomadora, possibilitando a identificação de mudanças no comportamento financeiro.

Na operacionalização do crédito estudado, o mecanismo de antecipação e vinculação de recebíveis de cartões é estruturado de forma a garantir amortização automática do saldo devedor. Inicialmente, no momento da contratação, a empresa tomadora autoriza a constituição de gravame eletrônico sobre os recebíveis de cartão de crédito e/ou débito. Esse gravame é formalizado em entidade registradora autorizada pelo Banco Central e vinculado ao arranjo de pagamento (combinação de bandeira e modalidade), de modo que independe do adquirente utilizado pela empresa. Assim, qualquer venda futura realizada no cartão dentro daquele arranjo é identificada como parte do fluxo garantido.

Após o registro, a SCD consulta as bases das registradoras para verificar a inexistência de outros gravames anteriores e formaliza a operação, evitando a cessão múltipla do mesmo ativo. A partir desse momento, todos os recebíveis oriundos das vendas no cartão são automaticamente direcionados ao credor, que utiliza um percentual acordado em contrato para amortização diária do empréstimo. Esse procedimento elimina a necessidade de boletos ou transferências manuais pelo tomador, reduzindo atrasos e facilitando a gestão de caixa.

A característica central do modelo é que o fluxo de recebíveis segue para a quitação da dívida independentemente da adquirente em que a empresa processe as vendas. Por estar “travado” no arranjo, o recebível é capturado e liquidado em favor da SCD assim que é

registrado, conferindo maior segurança à instituição e previsibilidade ao contrato. O credor, por sua vez, passa a ter acesso em tempo quase real às informações registradas, o que possibilita o monitoramento contínuo da geração de receitas, a identificação de queda de faturamento e o ajuste de limites de crédito.

Portanto, o uso de recebíveis de cartão como colateral representa uma alternativa inovadora. Essa dinâmica reduz significativamente o risco de inadimplência, garante a vinculação efetiva do fluxo de caixa ao pagamento da dívida e viabiliza o acesso ao crédito mesmo para empresas que não dispõem de garantias reais tradicionais.

2.6 Pesquisas sobre o tema central da pesquisa publicadas no Brasil

Nos últimos anos, diversas pesquisas nacionais têm se debruçado sobre o estudo da inadimplência, risco de crédito e insolvência, com especial atenção à aplicação de modelos estatísticos para previsão e análise de comportamento financeiro de empresas e indivíduos. O Quadro 1 apresenta uma seleção de estudos publicados no Brasil, que evidenciam o uso recorrente da regressão logística como metodologia predominante.

Esses trabalhos exploram desde a construção de modelos de *credit scoring* até a identificação de variáveis determinantes de inadimplência e solvência, com resultados que apontam para a relevância de características contratuais, setoriais e macroeconômicas na predição do risco. Essa produção acadêmica fornece uma base sólida e atualizada para a presente pesquisa.

Quadro 1 - Pesquisas sobre o tema publicadas no Brasil

(continua)

| Título | Autores /Ano | Objetivo e Resultados | Metodologia |
|---|-------------------------------------|--|---------------------|
| Proposição de modelos de previsão de risco de crédito para pequenas e médias empresas por meio da Regressão Logística | FÜHR, F. (2022) | Desenvolver cinco modelos de scoring para PMEs. Modelos apresentaram boa acurácia com uso de variáveis não contábeis e não auditáveis. | Regressão logística |
| Modelagem com regressão logística para análise de concessão de crédito | BESERRA, R. S. <i>et al.</i> (2022) | Demonstrar a eficiência da regressão logística como técnica de mineração de dados para análise de concessão de crédito bancário. O modelo evidenciou bom desempenho na discriminação entre clientes adimplentes e inadimplentes. | Regressão logística |

(continua)

| | | | |
|---|--|---|---|
| Identificação de indicadores para previsão de insolvência das distribuidoras de energia elétrica por meio de regressão logística para dados em painel | DA SILVA, S. F. P.; PESSANHA, J. F. M. (2022) | Identificar indicadores relevantes de insolvência em distribuidoras de energia. As análises realizadas identificaram cinco indicadores relevantes, nomeadamente o lucro líquido, a dependência/independência financeira, a liquidez geral e as perdas não técnicas. | Regressão logística para dados em painel |
| Determinantes de inadimplência e de recuperação de crédito em um banco de desenvolvimento | AMARAL, G. H. de O. (2020) | Analisar fatores que influenciam inadimplência e recuperação de crédito. Fatores contratuais, individuais e macroeconômicos são relevantes. | Regressão logística |
| Aplicação e análise da eficácia de modelos brasileiros de previsão de insolvência para empresas | AZEREDO, V. C. de <i>et al.</i> (2019) | Comparar modelos clássicos e recentes de previsão de insolvência. Modelos mais recentes mostraram maior equilíbrio na identificação de solvência. | Comparativo de modelos de previsão de insolvência |
| Uma aplicação do modelo de regressão logística na previsão de falência empresarial no Brasil | GUIMARÃES, P. R. F.; RESENDE FILHO, M. A. (2018) | Aplicar regressão logística para prever inadimplência empresarial com antecedência de um ano. Modelo obteve bom ajuste e alta predição. | Regressão logística |
| Que fatores determinam o nível de endividamento das pequenas e médias empresas no Brasil | VILLELA, L. M. <i>et al.</i> (2017) | Investigar os determinantes da estrutura de capital de PMEs brasileiras. Resultados indicam que tamanho, tangibilidade e crescimento são determinantes do endividamento total, enquanto tamanho e tangibilidade explicam o endividamento de longo prazo, com significância estatística. | Regressão com dados em painel |
| A inadimplência das empresas no Brasil e seus determinantes macroeconômicos | OLIVEIRA, J. C. T. <i>et al.</i> (2016) | Analisar relação entre inadimplência e variáveis macroeconômicas (2003–2015). Regime de alta inadimplência é mais persistente; juros e renda influenciam mais em regime de baixa, inflação e câmbio em regime de alta. | Regressão Markov Switching |
| Determinantes da inadimplência no crédito habitacional direcionado à classe média emergente brasileira | LOCATELLI, R. L. <i>et al.</i> (2015) | Identificar fatores de inadimplência em crédito habitacional. Renda comprometida, sexo, idade, estado civil e escolaridade influenciam inadimplência. | Regressão logística |

(continuação)

| | | | |
|--|---|---|--|
| Fatores condicionantes de inadimplência em processos de concessão de crédito a micro e pequenas empresas do Estado de Minas Gerais | CAMARGOS, M. A. <i>et al.</i> (2010) | Identificar fatores de inadimplência em financiamentos do BDMG. Porte, setor, tempo de atividade, informatização e perfil dos sócios influenciam a inadimplência. | Regressão logística |
| Uma sistemática para construção e escolha de modelos de previsão de risco de crédito | SELAU, L. P. R., & Ribeiro, J. L. D. (2008) | Propor sistemática para construção de modelos de risco de crédito. Redes neurais tiveram desempenho ligeiramente superior. | Análise discriminante, regressão logística e redes neurais |

Fonte: Elaborado pela autora com base em pesquisas levantadas sobre o tema (2025).

2.7 Pesquisas sobre o tema central da pesquisa publicadas no exterior

A evolução das metodologias estatísticas aplicadas à previsão de inadimplência e ao risco de crédito em Pequenas e Médias Empresas (PMEs) tem sido objeto de crescente atenção no cenário internacional. Diversas pesquisas desenvolvidas em diferentes países vêm contribuindo para o aperfeiçoamento de modelos preditivos, incorporando variáveis tradicionais e inovadoras, como aspectos estratégicos e critérios ESG. As abordagens mais recentes combinam técnicas clássicas, como a regressão logística, com métodos mais sofisticados, como redes neurais artificiais e modelos híbridos, visando maior precisão na identificação de padrões de risco. O Quadro 2 apresenta um conjunto de estudos internacionais relevantes, que ilustram diferentes contextos econômicos, setores produtivos e estratégias metodológicas aplicadas à previsão de inadimplência e insolvência entre PMEs.

Quadro 2 - Pesquisas sobre o tema publicadas no exterior

(continua)

| Título | Autores /Ano | Objetivos e Resultados | Metodologia |
|--|--------------------------|--|---------------------|
| Modelos de Previsão de Falências e os Fatores ESG nas Empresas Portuguesas | RODRIGUE S, F. R. (2024) | Analisar modelos de previsão de falência em empresas industriais portuguesas, incorporando variáveis financeiras e estratégicas (ESG). Variáveis de liquidez e atividade foram estatisticamente significativas; fatores ESG como número de subsidiárias, diretores, formação e inovação mostraram impacto relevante na previsão de falência. | Regressão logística |

(continuação)

| | | | |
|---|--|--|--|
| Previsão de Risco de Crédito de PMEs na China em Financiamento de Cadeia de Suprimentos por Regressão Logística, Redes Neurais Artificiais e Modelos Híbridos | ZHU, Y. <i>et al.</i> (2016) | Comparar modelos logísticos, redes neurais e híbridos na previsão de risco de crédito de PMEs chinesas em financiamento de cadeia de suprimentos. O modelo híbrido do tipo III teve o melhor desempenho preditivo geral para sinais positivos e negativos. | Regressão logística e redes neurais artificiais. |
| Modelo Híbrido de Inovação Financeira para Inadimplência no Crédito a PMEs | LI, Y.; NISKANEN, M.; KOLEHMAINEN, M. (2016) | Propor um modelo híbrido mais preciso de risco de crédito para PMEs. O modelo ANN/logístico foi mais preciso que os modelos isolados, contribuindo para redução de erros, menores exigências de capital e taxas de juros. | Modelo híbrido com regressão logística e ANN |
| Previsão de Insolvência nas PME do setor de materiais de construção | GIRÃO, A. P. P. (2015) | Criar um modelo preditivo de insolvência para PME no setor de materiais de construção. Modelos preditivos com 90% (2014) e 100% (2008) de acurácia dois anos antes da insolvência. | Análise Discriminante Multivariada |
| Modelagem da Previsão de Inadimplência de Pequenas Empresas por Redes Neurais Artificiais: Uma Análise Empírica de Pequenas Empresas Italianas | CIAMPI, F.; GORDINI, N. (2013) | Avaliar a eficácia das redes neurais artificiais na previsão de inadimplência de pequenas empresas italianas. ANNs superaram métodos tradicionais, com melhor desempenho para empresas menores e localizadas na região central da Itália. | Redes neurais artificiais |

Fonte: Elaborado pela autora com base em pesquisas levantadas sobre o tema (2025).

3 METODOLOGIA

De acordo com Gil (2002), a pesquisa pode ser entendida como um processo racional com base sistemática que permite ao pesquisador encontrar soluções para questões em distintas áreas do saber. Para isso, é fundamental empregar variados métodos e técnicas que auxiliem na concretização dos objetivos propostos pelo estudo.

Este estudo caracteriza-se como uma pesquisa aplicada, com abordagem quantitativa, orientada à resolução de um problema prático e recorrente no âmbito profissional: a necessidade de acompanhamento contínuo do risco de crédito em carteiras ativas de clientes. Para tal, adota-se a regressão logística binomial como técnica estatística, apropriada para situações em que a variável dependente é dicotômica (adimplente/inadimplente).

3.1 Técnica de Regressão Logística

A técnica de regressão logística é uma ferramenta estatística que, assim como a regressão múltipla, utiliza coeficientes estimados para cada variável independente. O nome "logística" decorre da aplicação da função logit à variável dependente. Conforme explicado por Hair *et al.* (2009), essa abordagem segue um procedimento semelhante ao da previsão da variável dependente com base em uma equação composta por coeficientes logísticos.

Nessa forma de regressão, a variável dependente é do tipo categórica, enquanto as variáveis independentes podem ser tanto contínuas quanto categóricas. Sua aplicação mais comum se dá quando a variável dependente é dicotômica, ou seja, apresenta apenas duas categorias distintas — o que caracteriza a regressão logística binária. Nessa situação, pressupõe-se que os resultados sejam independentes entre si e mutuamente exclusivos, o que significa que cada observação pode pertencer a apenas uma categoria.

Os parâmetros do modelo são estimados utilizando o método da máxima verossimilhança, conforme apontado por Hosmer e Lemeshow (1989). Vale destacar que a presença de multicolinearidade entre as variáveis independentes pode comprometer os resultados da análise, tornando essencial sua verificação antes da implementação do modelo, como alertam Vieira e Ribas (2011).

A regressão logística é amplamente utilizada na modelagem de risco de crédito devido à sua capacidade de estimar a probabilidade de inadimplência com base em variáveis explicativas. Segundo Beserra *et al.* (2022), essa técnica permite discriminar eficazmente entre clientes adimplentes e inadimplentes.

De acordo com Brito e Assaf Neto (2008), a análise dos resultados em uma regressão logística é baseada no conceito de chance. Em termos práticos, especialmente na regressão logística binária, a chance pode ser entendida como a razão entre a probabilidade de um evento acontecer e a probabilidade de esse mesmo evento não acontecer (VIEIRA; RIBAS, 2011). Por se tratar de uma razão entre probabilidades, é comum a utilização do termo "razão de chance", também conhecido como *odds ratio*.

A fórmula da regressão logística serve para modelar a probabilidade de ocorrência de um evento (quando a variável dependente é categórica, geralmente binária: 0 ou 1). A equação básica da regressão logística binária é:

$$\text{logit}(P) = \ln \left(\frac{P}{1-P} \right) = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k \quad (1)$$

Na equação acima:

- $\text{logit}(P)$ representa o logaritmo natural da razão de chances de ocorrência do evento de interesse (por exemplo, inadimplência). Trata-se da transformação que lineariza a relação entre as variáveis independentes e a variável dependente.
- A razão de chances (ou *odds*) é dada por $\frac{P}{1-P}$, onde:
 - P é a probabilidade de o evento ocorrer;
 - 1-P é a probabilidade de o evento não ocorrer.
- O intercepto β_0 corresponde ao valor do logit quando todas as variáveis independentes são iguais a zero.
- Os coeficientes $\beta_1, \beta_2, \dots, \beta_k$ representam o efeito de cada variável explicativa X_1, X_2, \dots, X_k sobre o logit da probabilidade.
 - Cada coeficiente indica o quanto o logit varia a cada unidade de aumento da respectiva variável independente, mantendo as demais constantes.
 - As variáveis X_i podem ser contínuas (como renda, idade ou tempo de empresa) ou categóricas (como sexo ou setor de atividade).

Cada coeficiente indica o quanto o logit varia a cada unidade de mudança na respectiva variável independente, mantendo as demais constantes. Quando um coeficiente é positivo, isso indica que o aumento da variável está associado ao aumento da chance de o evento ocorrer; quando é negativo, o efeito é inverso.

3.2 Descrição da pesquisa

Os dados utilizados neste estudo foram extraídos da base interna de uma SCD especializada na concessão de crédito para PMEs. A data-base considerada para a análise é 31 de março de 2025. A amostra é composta por registros de empresas que já tomaram crédito na instituição, contemplando informações cadastrais, contratuais, comportamentais e financeiras.

Cabe destacar que 100% das operações analisadas são garantidas por recebíveis de cartão, o que reduz significativamente o risco de crédito da carteira e confere maior previsibilidade ao comportamento de pagamento dos clientes.

3.2.1 Critérios de Seleção da Amostra

A SCD em questão tem como público-alvo pequenas e médias empresas (PMEs), com forte presença nos setores de comércio e serviços varejistas. Sua carteira concentra-se em negócios como restaurantes, bares, salões de beleza, lojas de roupas, postos de combustíveis, entre outros. Essas empresas buscam na SCD uma alternativa mais ágil e menos burocrática para acessar crédito destinado a capital de giro, expansão ou investimentos.

O crédito é concedido de forma automática e em escala apenas para empresas que já possuem relacionamento com a adquirente do grupo (operadora de meios de pagamento). Essa integração permite à SCD avaliar o fluxo de vendas dos clientes e estruturar ofertas de crédito rápidas e simplificadas, atendendo um segmento que enfrenta barreiras significativas nas instituições financeiras convencionais.

A base de dados utilizada nesta pesquisa contempla contratos de capital de giro ativos na data de 31 de março de 2025, firmados por pessoas jurídicas (CNPJ). Foram considerados apenas contratos com no mínimo 120 dias desde a data de concessão, garantindo tempo hábil para observação do comportamento de pagamento. A amostra foi refinada por meio de filtros específicos, com exclusão de:

- Contratos aprovados por análise manual (mantidos apenas os contratos aprovados por esteira automática);
- Contratos renegociados.
- Contratos gerados para testes internos com perfis fora do padrão de aprovação institucional;

Para clientes com múltiplos contratos, foi mantido apenas aquele com maior valor liberado.

3.2.2 Coleta e Tratamento dos Dados

As informações foram extraídas a partir de bases consolidadas da instituição, hospedadas em bancos de dados internos. Durante a extração, foram aplicadas medidas de segurança e privacidade, com a exclusão ou anonimização de informações confidenciais e identificadores pessoais dos clientes, por meio de codificações aleatórias.

Conforme Shang *et al.* (2015), a qualidade e o tratamento adequado dos dados impactam diretamente na precisão dos modelos preditivos. Assim, a base passou por um processo rigoroso de preparação, que incluiu:

- Remoção de registros incompletos ou inconsistentes, de forma a evitar viés e distorções nos resultados;
- Codificação de variáveis categóricas por meio de *one-hot encoding*, convertendo cada categoria em variáveis binárias, para facilitar sua interpretação pelo modelo;
- Equalização da amostra: considerando o desbalanceamento natural entre os grupos, foi realizada a exclusão aleatória de clientes adimplentes até atingir o equilíbrio com o número de inadimplentes. A amostra final foi composta por 1.200 clientes inadimplentes e 1.200 clientes adimplentes.

3.2.3 Construção da Data de Corte

As informações comportamentais dos clientes foram analisadas a partir de uma data de corte, definida com o objetivo de preservar a natureza preditiva da modelagem.

- Para os inadimplentes, a data de corte foi estabelecida como 90 dias antes da primeira ocorrência em que o cliente ultrapassou 90 dias de atraso.
- Para os adimplentes, a data de corte corresponde a 90 dias antes da última quitação de parcela observada até a data-base de 31/03/2025.

A partir dessa data de corte, foram extraídas todas as variáveis explicativas utilizadas na modelagem, garantindo que apenas informações disponíveis antes do evento de inadimplência fossem consideradas. Essa estrutura é essencial para assegurar que todas as variáveis explicativas utilizadas no modelo sejam anteriores ao evento de inadimplência, respeitando a lógica temporal de predição.

3.2.4 Definição da Variável Dependente

A variável dependente da modelagem é a inadimplência, com natureza binária, definida com base no status do contrato na data-base:

- Adimplentes (0): contratos com zero dias de atraso em 31/03/2025;

- Inadimplentes (1): contratos com mais de 90 dias de atraso em ao menos uma parcela na data-base, conforme critério do BACEN.

Contratos com atraso entre 1 e 90 dias foram excluídos da amostra, visando garantir uma separação clara entre os grupos e assegurar maior precisão na modelagem estatística.

3.2.5 Seleção das Variáveis Independentes

As variáveis preditoras foram selecionadas com base na disponibilidade da base interna, na literatura especializada sobre risco de crédito e na experiência prática da equipe de análise da instituição. Conforme argumentam Gouvêa *et al.* (2015), a escolha criteriosa das variáveis explicativas impacta diretamente na acurácia e robustez dos modelos estatísticos.

Diversas variáveis foram inicialmente testadas, contudo, algumas foram excluídas em razão da presença de multicolinearidade, bem como de sua baixa significância estatística. O Quadro 3 apresenta a relação completa das variáveis testadas.

Quadro 3 - Variáveis independentes testadas

(continua)

| VARIÁVEL | SIGLA | DEFINIÇÃO / CÁLCULO |
|---------------------------------|-------|---|
| Setor de Atuação | SDA | Classificação da atividade econômica da empresa, agrupada em 10 principais segmentos. Variável categórica convertida em dummies (variáveis binárias). |
| Tempo de Fundação da Empresa | TEMPF | Quantidade de anos decorridos desde a data de constituição da empresa até a data de corte. |
| Localização Geográfica | LOC | Região do Brasil onde está situada a sede da empresa. Variável categórica transformada em dummies. |
| Rating de Concessão | RTC | Classificação interna de risco atribuída à empresa no momento da concessão do crédito, variando de 0,0 a 10. |
| CNPJ Baixado na Receita Federal | CNPJB | Situação cadastral da empresa junto à Receita Federal classificada como 'baixada'. Variável categórica convertida em dummies, em que 1 indica empresa baixada e 0 indica empresa ativa. |
| Valor do Crédito Concedido | VLCC | Montante (R\$) de capital de giro aprovado para o cliente na operação de crédito. |
| Valor da Parcela Mensal | VLPM | Valor (R\$) da prestação mensal contratada. |
| Tempo de Concessão | TEMPC | Número de dias decorridos entre a data de concessão do crédito e a data de corte. |
| Prazo Contratual | PZC | Quantidade total de parcelas previstas contratualmente, expressa em meses. |
| Valor do Saldo Devedor | VLSD | Valor presente (R\$), ainda em aberto, da operação de crédito na data de corte. |

(continua)

| | | |
|--|-------|--|
| Percentual do Saldo em Aberto | PCSA | Proporção entre o saldo devedor e o valor originalmente concedido. Indica o percentual ainda não quitado do contrato. Fórmula: $PCSA = VLSD / VLCC$. |
| Quantidade de Parcelas Atrasadas | QTPA | Número de parcelas vencidas e não pagas na data de corte. |
| Proporção de Parcelas Pagas | PPP | Razão entre o número de parcelas quitadas e o total de parcelas previstas no contrato. Fórmula: $PPP = \text{parcelas pagas} / PZC$. |
| Quantidade de Comunicações | QTC | Número de interações registradas entre o cliente e a instituição nos 30 dias anteriores à data de corte. |
| Quantidade de Instituições Financeiras | QTIFS | Número de instituições financeiras com as quais a empresa possuía vínculos de endividamento na data de corte. |
| Endividamento Total | EDT | Total (R\$) de dívidas da empresa em instituições financeiras na data de corte. |
| Quantidade de Restritivos | QTR | Número de registros restritivos vinculados à empresa na data de corte. |
| Percentual de Dias Fora do Esperado | PCFE | Proporção de dias, nos 90 dias anteriores à data de corte, em que o contrato esteve classificado no Farol de Pagamento como "Fora do Esperado". Fórmula: $PCFE = \text{dias Fora do Esperado} / 90$. |
| Percentual de Dias em Crítico | PCDC | Proporção de dias, nos 90 dias anteriores à data de corte, em que o contrato esteve classificado como "Crítico" no Farol de Pagamento. Fórmula: $PCDC = \text{dias em Crítico} / 90$. |
| Percentual de Dias em Atraso | PCEA | Proporção de dias, nos 90 dias anteriores à data de corte, em que o contrato esteve classificado como "Em Atraso" no Farol de Pagamento. Fórmula: $PCEA = \text{dias em Atraso} / 90$. |
| Faturamento de Recebíveis | FAT | Valor total (R\$) transacionado em recebíveis pela empresa nos 90 dias anteriores à data de corte. |
| Ticket Médio | TKM | Valor médio por transação de recebíveis no período de 90 dias antes da data de corte. Calculado pela razão entre o faturamento total e o número de transações: $TKM = FAT / \text{número de transações}$. |
| Varição no Faturamento de Recebíveis | VARFR | Varição percentual no valor de faturamento com recebíveis entre o penúltimo e o último mês antes da data de corte. |
| Farol de Pagamento | FPG | Classificação categórica do contrato na data de corte conforme o Farol de Pagamento. Transformado em variáveis dummy (e.g., "Fora do Esperado", "Crítico"). |
| Quantidade de Dias de Atraso | QTDA | Total de dias de atraso registrados para o contrato na data de corte. |

(continuação)

| | | |
|---|-------|--|
| Quantidade de Dias sem Acesso à Plataforma | QTDSA | Intervalo, em dias, sem logins ou acessos do cliente à plataforma, contado da data do último acesso até a data de corte. Fórmula: QTDSA = data de corte - data do último acesso. |
| Variação na Quantidade de Transações na Conta | VARQT | Variação percentual na quantidade de transações na conta corrente entre o penúltimo e o último mês anterior à data de corte. |

Fonte: Elaborado pela autora (2025).

A empresa utiliza recebíveis de cartão como garantia das operações de crédito concedidas às PMEs. Para garantir a liquidação das parcelas em um prazo máximo de 30 dias, é realizado um cálculo diário que determina o valor a ser amortizado com base nos recebíveis gerados pelo cliente. Dessa forma, uma parte dos recebíveis é automaticamente destinada à amortização da parcela devida. Caso o cliente não atinja o valor esperado de pagamento diário, ele é classificado como “Crítico” ou “Fora do esperado” do Farol de Pagamento do sistema de monitoramento. Essa classificação é utilizada como variável comportamental no modelo de *score* dinâmico, refletindo diretamente a capacidade do cliente de honrar seus compromissos financeiros dentro do prazo estipulado.

3.2.5.1 Teste de Multicolinearidade

Tendo em vista que a ausência de multicolinearidade é um dos pressupostos fundamentais da regressão logística, foi realizada uma análise para verificar esse aspecto. A colinearidade ocorre quando duas variáveis independentes apresentam uma correlação elevada entre si, sendo a multicolinearidade o resultado de alta correlação entre várias variáveis independentes, sem o envolvimento da variável dependente (HAIR *et al.*, 2009; VIEIRA; RIBAS, 2011). Esse fenômeno pode comprometer a análise dos resultados, uma vez que variáveis altamente correlacionadas podem estar representando a mesma dimensão, dificultando a identificação de qual delas tem maior relevância (VIEIRA; RIBAS, 2011).

Para avaliar a multicolinearidade, utilizou-se o cálculo do Fator de Inflação da Variância (VIF), sendo que um valor de VIF igual ou superior a 10 é geralmente considerado um indicativo de problema (HAIR *et al.*, 2009). Quando esse limite é ultrapassado, recomenda-se a exclusão da variável do modelo. Dessa forma, variáveis altamente correlacionadas foram excluídas ou combinadas, a fim de evitar redundância e preservar a precisão do modelo. A Tabela 1 apresenta as variáveis removidas.

Tabela 1 - Variáveis removidas pelo teste de multicolinearidade

| Variáveis | VIF |
|---------------------------------------|----------|
| Localização Geográfica - Sudeste | 303,2548 |
| Localização Geográfica - Nordeste | 200,1398 |
| Localização Geográfica – Centro Oeste | 136,0703 |
| Localização Geográfica - Sul | 123,0739 |
| Localização Geográfica - Norte | 91,1742 |
| Proporção de Parcelas Pagas | 35,0325 |
| Valor do Crédito Concedido | 29,3532 |
| Valor da Parcela Mensal | 23,0786 |
| Tempo de Concessão | 19,5926 |
| Valor do Saldo Devedor | 11,1081 |
| Quantidade de Parcelas Atrasadas | 10,6485 |

Fonte: Elaborado pela autora (2025).

Após a remoção das variáveis com VIF superior a 10, um novo teste de multicolinearidade foi realizado. Essa etapa confirmou que todas as variáveis remanescentes se encontravam dentro dos limites aceitáveis, satisfazendo assim um dos pressupostos essenciais para a aplicação da regressão logística. A Tabela 2 apresenta o resultado do novo teste.

Tabela 2 - Resultados do Teste de Multicolinearidade (VIF)

(continua)

| Variáveis | VIF |
|--|--------|
| Farol de Pagamento - Crítico | 3,0567 |
| Quantidade de Dias de Atraso | 3,0247 |
| Percentual de Dias em Atraso | 2,9575 |
| Percentual de Dias em Crítico | 2,3062 |
| Rating de Concessão | 1,7240 |
| Prazo Contratual | 1,6400 |
| Percentual do Saldo em Aberto | 1,4909 |
| Percentual de Dias Fora do Esperado | 1,4580 |
| Faturamento de Recebíveis | 1,3957 |
| Quantidade de Dias sem Acesso à Plataforma | 1,3285 |
| Quantidade de Instituições Financeiras | 1,2206 |
| Tempo de Fundação da Empresa | 1,2180 |

| | (continuação) |
|--|---------------|
| Endividamento Total | 1,2314 |
| Farol de Pagamento - Fora do esperado | 1,1925 |
| Ticket Médio | 1,1733 |
| Setor de Atuação - Serviços Corporativos e Administrativos | 1,1444 |
| Varição na Quantidade de Transações na Conta | 1,1408 |
| Setor de Atuação - Saúde, Bem-estar e Farmacêuticos | 1,1287 |
| CNPJ Baixado na Receita Federal | 1,1265 |
| Setor de Atuação - Tecnologia e Comunicação | 1,1250 |
| Setor de Atuação - Transportes e Logística | 1,1068 |
| Setor de Atuação - Educação e Atividades Culturais | 1,0832 |
| Setor de Atuação - Indústria e agropecuária | 1,0749 |
| Setor de Atuação - Turismo e Eventos | 1,0676 |
| Setor de Atuação - Construção e Infraestrutura | 1,0358 |
| Quantidade de Restritivos | 1,0357 |
| Quantidade de Comunicações | 1,0285 |
| Setor de Atuação - Comércio e Varejo | 1,3123 |
| Varição no Faturamento de Recebíveis | 1,0081 |

Fonte: Elaborado pela autora (2025).

3.2.6 Técnica Estatística Aplicada

A modelagem preditiva foi realizada por meio do *software* IBM SPSS *Statistics*, utilizando-se a regressão logística binomial, técnica apropriada para estimativas de variáveis dependentes binárias e interpretação dos efeitos marginais das variáveis explicativas.

O processo de modelagem contemplou as seguintes etapas:

- Inclusão das variáveis preditoras previamente selecionadas;
- Análise dos coeficientes estimados e teste de significância estatística por meio do teste de Wald, com nível de significância de 5%;
- Exclusão das variáveis que não apresentaram significância estatística;
- Validação e análise de desempenho do modelo ajustado.

4 RESULTADOS E ANÁLISE

4.1 Resultados dos Testes Estatísticos

Foram obtidos 2.400 registros contendo a variável dependente categórica Situação do Cliente, composta por duas categorias: inadimplente e adimplente.

Após as etapas de tratamento e equalização dos dados, bem como a verificação da ausência de multicolinearidade, realizou-se o teste de significância inicial para todas as variáveis independentes remanescentes. O objetivo dessa análise preliminar foi identificar e remover variáveis que não apresentassem relação estatisticamente significativa com a variável dependente (inadimplência), antes da construção final do modelo de regressão logística. Esse processo de seleção é essencial para garantir a parcimônia e a robustez do modelo, ao eliminar preditores que poderiam introduzir ruído ou não contribuir de forma relevante para a capacidade preditiva.

A Tabela 3 apresenta os resultados detalhados desse teste inicial, incluindo os respectivos valores de significância (p) para cada variável.

Tabela 3 - Seleção inicial de variáveis com base nos valores de p

(continua)

| | B | S.E. | Wald | df | Sig. | Exp(B) | 95% C.I. para EXP(B) | |
|--|---------|--------|-------|----|-------|--------|----------------------|------------|
| | | | | | | | Inferior | Superior |
| Setor de Atuação - Comércio e Varejo | 0,043 | 0,4853 | 0,008 | 1 | 0,929 | 1,044 | 0,4033 | 2,7026 |
| Setor de Atuação - Construção e Infraestrutura | 2,2822 | 4,4697 | 0,261 | 1 | 0,610 | 9,7982 | 0,0015 | 62483,0642 |
| Setor de Atuação - Educação e Atividades Culturais | 0,6366 | 1,4838 | 0,184 | 1 | 0,668 | 1,89 | 0,1032 | 34,6292 |
| Setor de Atuação - Indústria e agropecuária | -1,3866 | 0,9408 | 2,172 | 1 | 0,141 | 0,2499 | 0,0395 | 1,5798 |
| Setor de Atuação - Saúde, Bem-estar e Farmacêuticos | -0,2968 | 0,8576 | 0,12 | 1 | 0,729 | 0,7432 | 0,1384 | 3,9913 |
| Setor de Atuação - Serviços Corporativos e Administrativos | -0,9485 | 0,6069 | 2,442 | 1 | 0,118 | 0,3873 | 0,1179 | 1,2726 |
| Setor de Atuação - Tecnologia e Comunicação | -0,9773 | 0,7613 | 1,648 | 1 | 0,199 | 0,3763 | 0,0846 | 1,6733 |

(continuação)

| | | | | | | | | |
|--|-------------|--------|--------|---|-------|---------------|-----------|------------|
| Setor de Atuação - Transportes e Logística | 1,5951 | 1,2222 | 1,703 | 1 | 0,192 | 4,9287 | 0,4491 | 54,088 |
| Setor de Atuação - Turismo e Eventos | 1,1944 | 1,7455 | 0,468 | 1 | 0,494 | 3,3016 | 0,1079 | 101,0389 |
| Tempo de Fundação da Empresa | -0,0857 | 0,0269 | 10,159 | 1 | <,001 | 0,9179 | 0,8707 | 0,9675 |
| Rating de Concessão | -0,0477 | 0,1354 | 0,124 | 1 | 0,725 | 0,9535 | 0,7312 | 1,2432 |
| CNPJ Baixado na Receita Federal | 2,1067 | 0,8278 | 6,476 | 1 | 0,011 | 8,2209 | 1,6228 | 41,6468 |
| Prazo Contratual | -0,3551 | 0,0902 | 15,489 | 1 | <,001 | 0,7011 | 0,5875 | 0,8367 |
| Percentual do Saldo em Aberto | 6,1205 | 0,9147 | 44,773 | 1 | <,001 | 455,0803 | 75,7701 | 2733,2427 |
| Quantidade de Comunicações | -0,0728 | 0,0752 | 0,936 | 1 | 0,333 | 0,9298 | 0,8024 | 1,0775 |
| Quantidade de Instituições Financeiras | 0,1159 | 0,1859 | 0,389 | 1 | 0,533 | 1,1229 | 0,78 | 1,6164 |
| Endividamento Total | 0 | 0 | 0,09 | 1 | 0,764 | 1,2 | 1,2 | 1,2 |
| Quantidade de Restritivos | 0,0233 | 0,0221 | 1,115 | 1 | 0,291 | 1,0236 | 0,9802 | 1,0688 |
| Percentual de Dias Fora do Esperado | -0,0148 | 0,0085 | 3,048 | 1 | 0,081 | 0,9853 | 0,9691 | 1,2018 |
| Percentual de Dias em Crítico | 0,0023 | 0,0106 | 0,047 | 1 | 0,829 | 1,2023 | 0,9817 | 1,0233 |
| Percentual de Dias em Atraso | 0,1479 | 0,0499 | 8,806 | 1 | 0,003 | 1,1595 | 1,0515 | 1,2785 |
| Faturamento de Recebíveis | 0 | 0 | 0,081 | 1 | 0,776 | 1,2 | 1,2 | 1,2 |
| Ticket Médio | -0,0004 | 0,0001 | 12,391 | 1 | <,001 | 0,9996 | 0,9994 | 0,9998 |
| Varição no Faturamento de Recebíveis | 0,0012 | 0,003 | 0,155 | 1 | 0,694 | 1,2012 | 0,9952 | 1,1972 |
| Farol de Pagamento Crítico | 10,235 1 | 1,0418 | 96,52 | 1 | <,001 | 27864,85 2 | 3616,3902 | 214703,046 |
| Farol de Pagamento Fora do esperado | 3,5692 | 1,0725 | 11,076 | 1 | 0,001 | 35,4873 | 4,337 | 290,3723 |
| Quantidade de Dias de Atraso | 0,2965 | 0,0951 | 9,72 | 1 | 0,002 | 1,3451 | 1,1164 | 1,6206 |
| Quantidade de Dias sem Acesso à Plataforma | 0,0382 | 0,0069 | 30,425 | 1 | <,001 | 1,0389 | 1,0249 | 1,0531 |
| Varição na Quantidade de Transações na Conta | -0,1525 | 0,0709 | 4,634 | 1 | 0,031 | 0,8585 | 0,7472 | 0,9864 |
| Constante | -4,6934 | 1,5012 | 9,775 | 1 | 0,002 | 0,0092 | 0,0005 | 0,1736 |

Fonte: Elaborado pela autora (2025).

Foi realizada a remoção das variáveis com valor de p superior a 0,05. Por fim, as variáveis independentes mantidas foram: Tempo de fundação da empresa, Prazo contratual, Percentual do saldo em aberto, Percentual de dias em atraso nos últimos 90 dias, *Ticket Médio* das vendas, Quantidade de dias em atraso, Quantidades de dias sem acesso a plataforma, Variação na quantidade de transações na conta, CNPJ baixado na Receita Federal, Farol de pagamento Crítico e Farol de pagamento Fora do esperado.

Após essa etapa, foi conduzida a análise de regressão logística binária propriamente dita.

4.2 Resumo do Processamento dos dados

A Tabela 4 apresenta um resumo do processamento efetuado, evidenciando a inexistência de casos omissos.

Tabela 4 - Resumo de processamento

| Casos considerados | | N | Porcentagem |
|------------------------|---------------------|------|-------------|
| Casos selecionados | Incluído na análise | 2400 | 100,0 |
| | Casos omissos | 0 | 0,0 |
| | Total | 2400 | 100,0 |
| Casos não selecionados | | 0 | 0,0 |
| Total | | 2400 | 100,0 |

Fonte: Elaborado pela autora (2025).

4.3 Resultado Bloco 0

A Tabela 5 apresenta os resultados da classificação correspondente ao Bloco 0 da regressão logística. Neste estágio inicial, o modelo é estimado sem a inclusão de variáveis independentes, permitindo a avaliação da taxa de acerto baseada apenas nos resultados observados em comparação com os valores esperados, sem considerar qualquer influência explicativa das variáveis independentes.

Tabela 5 - Tabela de classificação – Bloco 0

| Observado | | Previsto | | Porcentagem correta |
|--------------------|--------------|------------|--------------|---------------------|
| | | Adimplente | Inadimplente | |
| Flag | Adimplente | 0 | 1200 | 0 |
| Inadimplência | Inadimplente | 0 | 1200 | 100 |
| Porcentagem global | | | | 50 |

Fonte: Elaborado pela autora (2025).

Conforme observado, o modelo estimado sem a inclusão de variáveis independentes apresentou uma taxa de acerto de 50%. Espera-se que, com a inserção das variáveis explicativas, essa porcentagem aumente, evidenciando a relevância e justificando a inclusão dessas variáveis no modelo.

4.4 Teste de Omnibus do Modelo de Coeficientes

A Tabela 6 apresenta os resultados iniciais do Bloco 1 da regressão logística, etapa em que todas as variáveis independentes foram incluídas no modelo. O teste de Omnibus avalia a melhora geral do modelo quando as variáveis independentes são adicionadas, neste caso revelou que as diferenças entre o Bloco 1 e o Bloco 0 foram estatisticamente significativas ($p < 0,001$). Esse resultado sugere que a inclusão das variáveis independentes contribui para melhorar a qualidade das predições.

Tabela 6 - Teste de Omnibus do Modelo de Coeficientes – Bloco 1

| | Qui-quadrado | df | Sig. |
|--------|--------------|----|-------|
| Etapa | 3069,778 | 11 | <,001 |
| Bloco | 3069,778 | 11 | <,001 |
| Modelo | 3069,778 | 11 | <,001 |

Fonte: Elaborado pela autora (2025).

4.5 R² de Nagelkerke

O pseudo R² do modelo, mais especificamente o R² de Nagelkerke, apresentou um valor de 0,962. Isso indica que as variáveis independentes que demonstraram associação significativa com a situação de inadimplência explicam aproximadamente 96,2% dessa situação, evidenciando a robustez e a eficácia do modelo.

Tabela 7 - Resumo do Modelo

| Verossimilhança de log -2 | R quadrado Cox & Snell | R quadrado Nagelkerke |
|---------------------------|------------------------|-----------------------|
| 257,329 ^a | 0,722 | 0,962 |

Fonte: Elaborado pela autora (2025).

4.6 Teste de Hosmer e Lemeshow

O teste de Hosmer e Lemeshow, utilizado para avaliar a qualidade do ajuste do modelo, apresentou um valor de $p = 0,985$. Esse resultado indica que, com as variáveis independentes incluídas, o modelo apresenta um bom ajuste aos dados. Conforme proposto pelos próprios autores Hosmer e Lemeshow (1989), este teste é fundamentado em uma estatística qui-quadrado (χ^2), que compara as frequências observadas e esperadas dos desfechos binários (0 e 1). A hipótese nula do teste assume que não há diferença entre os valores observados e os esperados. Quando o valor de p obtido é superior a 0,05, essa hipótese é aceita, e considera-se que o modelo apresenta um bom ajuste aos dados.

Tabela 8 - Teste de Hosmer e Lemeshow

| Qui-quadrado | df | Sig. |
|--------------|----|-------|
| 1,852 | 8 | 0,985 |

Fonte: Elaborado pela autora (2025).

4.7 Resultado Bloco 1

Assim como ocorreu na análise do Bloco 0 (Tabela 5), a Tabela 9 apresenta a classificação do Bloco 1, que contempla o modelo com todas as variáveis independentes, realizando a comparação entre os resultados observados e os valores estimados pelo modelo.

Tabela 9 - Tabela de classificação – Bloco 1

| Observado | | Previsto | | Porcentagem correta |
|---------------|--------------------|------------|--------------|---------------------|
| | | Adimplente | Inadimplente | |
| Flag | Adimplente | 1169 | 31 | 97,4 |
| Inadimplência | Inadimplente | 9 | 1191 | 99,3 |
| | Porcentagem global | | | 98,3 |

Fonte: Elaborado pela autora (2025).

Nota-se que o nível de acerto do modelo com as variáveis independentes é de 98,3%, maior que o do modelo sem as variáveis (50%), mostrando que as variáveis independentes melhoram os resultados alcançados.

4.8 Teste de Wald

Foi aplicado o teste de Wald para identificar quais variáveis independentes exercem influência significativa sobre a Inadimplência, bem como para determinar a direção dessa influência. A Tabela 10 apresenta os resultados desse teste, incluindo os coeficientes de regressão (B), o erro padrão (E.P.), os valores de significância (p), a razão de chances (Exp(B)) e o intervalo de confiança correspondente à razão de chances.

Tabela 10 - Coeficientes de regressão e razão de chance

| | | B | S.E. | Wald | df | Sig. | Exp(B) |
|-------|---------------------------------------|--------|-------|--------|----|-------|-----------|
| Sigla | Variável | | | | | | |
| TEMPF | Tempo de fundação da empresa | -0,078 | 0,024 | 10,254 | 1 | 0,001 | 0,925 |
| CNPJB | CNPJ baixado na Receita Federal | 2,15 | 0,793 | 7,355 | 1 | 0,007 | 8,586 |
| PZC | Prazo contratual | -0,34 | 0,075 | 20,758 | 1 | <,001 | 0,712 |
| PCSA | Perc. saldo em aberto | 5,977 | 0,838 | 50,934 | 1 | <,001 | 394,33 |
| PCEA | Perc. dias em atraso | 0,139 | 0,049 | 8,243 | 1 | 0,004 | 1,149 |
| TKM | Ticket médio | 0 | 0 | 13,061 | 1 | <,001 | 1 |
| FPGC | Farol de pagamento Crítico | 9,624 | 0,964 | 99,734 | 1 | <,001 | 15120,597 |
| FPGF | Farol de pagamento Fora do esperado | 3,187 | 1,086 | 8,61 | 1 | 0,003 | 24,223 |
| QTDA | Qnt. Dias de atraso | 0,299 | 0,122 | 6,001 | 1 | 0,014 | 1,349 |
| QTSA | Qnt. dias sem acesso a plataforma | 0,036 | 0,007 | 26,883 | 1 | <,001 | 1,037 |
| VARQT | Varição qnt. Transações conta 30 dias | -0,142 | 0,067 | 4,562 | 1 | 0,033 | 0,867 |
| | Constante | -5,124 | 1,422 | 12,991 | 1 | <,001 | 0,006 |

Fonte: Elaborado pela autora (2025).

Em análise ao teste de Wald, verifica-se que todas as variáveis independentes são estatisticamente significativas ($p < 0,05$), indicando influência sobre a inadimplência. Essa influência é interpretada por meio da razão de chances (Exp(B)), que estima a alteração na probabilidade de a variável dependente pertencer ao grupo-alvo, dado um aumento unitário na variável independente. Ou seja, a chance é a relação entre a probabilidade de um evento ocorrer e a probabilidade de ele não ocorrer. Portanto, um coeficiente positivo da variável independente indica que a chance estimada (de inadimplência) aumenta conforme o valor da variável

independente cresce. Por outro lado, um coeficiente negativo sugere que essa chance diminui com o aumento da variável independente. Quando o coeficiente é zero, isso significa que a chance permanece constante, independentemente do valor da variável independente, ou seja, a razão de chances é igual a 1 (VIEIRA; RIBAS, 2011).

Adotamos assim o seguinte modelo matemático para esses resultados:

$$\ln\left(\frac{p}{1-p}\right) = -5,124 - 0,078 \text{ TEMPF} - 0,340 \text{ PZC} + 5,977 \text{ PCSA} + 0,139 \text{ PCEA} + 0,000 \text{ TKM} + 0,299 \text{ QTDA} + 0,036 \text{ QTDSA} - 0,142 \text{ VARQT} + 2,150 \text{ CNPJB} + 9,624 \text{ FPGC} + 3,187 \text{ FPGF} \quad (2)$$

4.9 Análise dos Coeficientes

A análise dos coeficientes obtidos no modelo de regressão logística binária permitiu identificar a direção e a magnitude da influência das variáveis independentes na probabilidade de inadimplência dos clientes. Para as variáveis com coeficiente negativo, observa-se uma redução da chance de inadimplência à medida que seus valores aumentam. Por outro lado, diversas variáveis apresentaram coeficientes positivos, indicando aumento significativo na probabilidade de inadimplência conforme seus valores aumentam.

4.9.1 Tempo de fundação da empresa

O tempo de fundação da empresa apresentou um coeficiente negativo de -0,078, indicando que, à medida que a empresa é mais antiga, a probabilidade de inadimplência diminui. Esse efeito é quantificado pela razão de chances (odds ratio), $\text{Exp}(B) = 0,925$, que significa que, para cada unidade adicional de tempo de fundação (por exemplo, cada ano), a chance de a empresa estar inadimplente é cerca de 7,5% ($1 - 0,925$) menor em relação a empresas mais novas.

Empresas mais antigas tendem a ser mais estáveis, com histórico operacional mais robusto e capacidade comprovada de adaptação ao mercado. Isso reduz o risco de inadimplência, pois essas empresas já passaram por ciclos econômicos e demonstraram resiliência.

Este resultado corrobora com estudo realizado de Camargos *et al.* (2010) que ao utilizar a variável tempo da empresa, identificaram que quanto maior o tempo em que a empresa está no mercado, menores são as chances de inadimplência. Ao comparar com empresas com menos de 1 ano no mercado, nota-se que aquelas que estão no mercado de 1 a 5 anos possuem uma

chance 35,9% inferior de estarem inadimplentes e aquelas com tempo superior a 5 anos têm as chances reduzidas em 50,5%.

Audretsch (1999) menciona que nos primeiros anos de vida de uma organização, são muitas as incertezas quanto às vendas, competência dos gestores e funcionários, adequação produtiva, fatores que, com o passar do tempo, têm sua influência negativa minimizada, fato que justificaria a sua melhora de desempenho e, conseqüentemente, sua capacidade de honrar os compromissos financeiros assumidos.

4.9.2 CNPJ Baixado na Receita Federal

Variáveis categóricas, como o CNPJ baixado na Receita Federal, têm grande impacto na probabilidade de inadimplência. O coeficiente da regressão logística para essa variável é de 2,15, o que significa que o logaritmo das chances de inadimplência aumenta 2,15 unidades para clientes com CNPJ baixado em comparação aos clientes com CNPJ ativo.

Transformado em odds ratio $\text{Exp}(B)$, o valor é 8,586, indicando que esses clientes têm cerca de 8,6 vezes mais chance de se tornarem inadimplentes. Em geral, valores de $\text{Exp}(B)$ maiores que 1 indicam aumento da chance do evento ocorrer, enquanto valores menores que 1 indicam redução.

Assim, tanto o coeficiente positivo quanto o elevado odds ratio mostram que ter o CNPJ baixado aumenta o risco de inadimplência. Um CNPJ baixado indica que a empresa foi formalmente encerrada. Na prática, isso significa que a empresa não opera mais, portanto, a chance de inadimplência é extremamente elevada, visto que não há mais atividade produtiva para geração de receita.

4.9.3 Prazo contratual

De forma similar, o prazo contratual mostrou coeficiente de -0,340, o que representa uma redução na chance de inadimplência para contratos de prazo maior. Tratando-se de razão chance (odds ratio), obtemos $\text{Exp}(B) = 0,712$, o que significa que a chance de inadimplência é cerca de 29% menor em contratos mais longos ($1 - 0,712$).

Contratos com prazos maiores costumam estar associados a maior confiança da instituição no cliente e à existência de um planejamento financeiro. Além disso, prazos maiores diluem o valor das parcelas, reduzindo o peso mensal no fluxo de caixa do cliente.

4.9.4 Percentual do Saldo em Aberto

O percentual do saldo em aberto, por exemplo, exibiu um coeficiente positivo elevado de 5,977, o que se traduz em um aumento no risco inadimplência para clientes com saldo em

aberto maior. A razão de chances ($\text{Exp}(B) = 394,33$) indica que clientes com aumento de uma unidade nessa variável têm cerca de 394 vezes mais probabilidade de se tornarem inadimplentes, mostrando que alterações significativas no saldo em aberto estão fortemente associadas à inadimplência.

Um saldo em aberto elevado, em relação ao valor originalmente concedido, indica que a empresa efetuou pagamentos parciais ou nenhum pagamento sobre o contrato, o que eleva significativamente a probabilidade de inadimplência. Por outro lado, contratos que apresentam maior amortização demonstram maior comprometimento financeiro do cliente e, conseqüentemente, menor risco de inadimplência.

4.9.5 Percentual de Dias em Atraso

Da mesma forma, o percentual de dias em atraso nos últimos 90 dias aumentou a chance de inadimplência em cerca de 15% para cada ponto percentual adicional ($\text{Exp}(B) = 1,149$).

O histórico recente de atraso reflete o comportamento de pagamento do cliente. Um maior percentual de dias em atraso nos últimos 90 dias é um indicativo claro de deterioração no comprometimento financeiro.

4.9.6 Ticket Médio

O *ticket* médio das vendas, apesar de ter sido incluído no modelo, não apresentou influência significativa, com coeficiente próximo a zero e *odds ratio* igual a 1, indicando que o valor médio das vendas não altera a probabilidade de inadimplência.

4.9.7 Farol de Pagamento Crítico e Fora do Esperado

As classificações do Farol de Pagamento, derivadas do monitoramento diário da amortização automática via recebíveis de cartão, apresentam forte associação com a probabilidade de inadimplência. Clientes classificados como “Crítico” exibem um aumento exponencial no risco de inadimplência, com uma chance superior a 15 mil vezes maior ($\text{Exp}(B) = 15.120,60$), indicando praticamente a certeza de inadimplência. De modo semelhante, a classificação “Fora do Esperado” eleva a chance de inadimplência em aproximadamente 24 vezes ($\text{Exp}(B) = 24,22$). Esses resultados demonstram que o comportamento de pagamento monitorado diariamente é um indicador extremamente sensível e eficaz para identificar clientes com alto risco de inadimplência, reforçando a importância do acompanhamento contínuo no modelo de score dinâmico.

4.9.8 Quantidade de dias em Atraso

A quantidade de dias em atraso na data de corte também eleva a chance em 34,9% ($\text{Exp}(B) = 1,349$).

Assim como o item anterior, a quantidade acumulada de dias de atraso no contrato aumenta significativamente a probabilidade de inadimplência. Mesmo atrasos de menor duração indicam dificuldades no cumprimento das obrigações financeiras, delineando um perfil distinto dos clientes adimplentes.

4.9.9 Quantidade de Dias sem Acesso à Plataforma

A quantidade de dias desde o último acesso à plataforma aumenta a chance em 3,7% para cada dia a mais de ausência ($\text{Exp}(B) = 1,037$).

A ausência de acessos pode indicar desinteresse, distanciamento do relacionamento com a instituição ou até descontinuidade das operações da empresa. Essa inatividade é um comportamento típico de clientes que tendem a deixar obrigações pendentes.

4.9.10 Variação na Quantidade de Transações na Conta

A variação na quantidade de transações na conta nos últimos 30 dias também foi negativa (-0,142), sugerindo que clientes com maior atividade nas transações apresentam 13,3% menos chance de inadimplência ($\text{Exp}(B) = 0,867$).

Um aumento na quantidade de transações reflete maior atividade financeira e dinâmica operacional da empresa, indicando saúde econômica e fluxo de caixa ativo. Empresas com elevada movimentação tendem a demonstrar melhor capacidade de honrar suas obrigações financeiras. Adicionalmente, observa-se que clientes inadimplentes frequentemente alteram suas instituições financeiras, o que resulta na redução da movimentação em suas contas, caracterizando um comportamento típico associado ao risco de crédito.

4.10 Aplicabilidade do modelo em situações hipotéticas

Esses resultados evidenciam que as variáveis relacionadas à saúde financeira e ao comportamento de pagamento do cliente são os principais preditores do risco de inadimplência, enquanto características como maior tempo de mercado, prazos contratuais mais longos e maior atividade transacional exercem efeito protetor.

Com o objetivo de demonstrar a aplicabilidade prática do modelo de regressão logística binária desenvolvido para prever a inadimplência, foram elaborados dois perfis hipotéticos de clientes com características contrastantes. Essa abordagem permite ilustrar como as variáveis

independentes influenciam a probabilidade estimada de inadimplência, conforme os coeficientes obtidos no modelo.

Tabela 11 - Perfis hipotéticos de clientes

| Variável | Cliente A (Baixo Risco) | Cliente B (Alto Risco) |
|--|-------------------------|------------------------|
| Tempo de fundação (anos) | 12 | 1 |
| Prazo contratual (meses) | 24 | 6 |
| Percentual saldo em aberto (%) | 10 | 80 |
| Percentual de dias em atraso (%) | 5 | 35 |
| Ticket médio (R\$) | 500 | 500 |
| Dias de atraso na data corte | 2 | 25 |
| Dias sem acesso à plataforma | 3 | 40 |
| Variação na quantidade de transações (%) | 15 | -30 |
| Situação do CNPJ | Ativo | Baixado |
| Farol de pagamento | Normal | Crítico |

Fonte: Elaborado pela autora (2025).

O primeiro perfil, denominado Cliente A, representa uma empresa com comportamento e características que indicam baixo risco de inadimplência. Essa empresa possui 12 anos de fundação, contrato com prazo de 24 meses, apenas 10% do saldo em aberto e 5% de dias em atraso nos últimos 90 dias. Seu *ticket* médio de vendas é de R\$ 500,00, apresenta somente dois dias de atraso na data de corte e realizou o último acesso à plataforma há apenas três dias. Além disso, houve uma variação positiva de 15% na quantidade de transações nos últimos 30 dias. A empresa mantém CNPJ ativo e o farol de pagamento encontra-se dentro da normalidade.

Com base nas características do Cliente A, observa-se que a maioria dos coeficientes associados a essas variáveis possui sinal negativo ou representa uma condição de estabilidade. Consequentemente, o valor do logaritmo das chances (*log-odds*) resultante é baixo (-12,805), levando a uma probabilidade estimada reduzida de inadimplência (0,00027%). Assim, o modelo sugere que esse cliente tem forte propensão à adimplência.

Em contraposição, o Cliente B apresenta um perfil de alto risco. Esta empresa possui apenas um ano de fundação, contrato com prazo de seis meses, 80% do saldo em aberto e 35% de dias em atraso nos últimos 90 dias. O ticket médio também é de R\$ 500,00, porém a empresa acumula 25 dias em atraso na data de corte e está há 40 dias sem acessar a plataforma. Adicionalmente, houve uma redução de 30% na quantidade de transações nos últimos 30 dias, o CNPJ encontra-se baixado na Receita Federal e o farol de pagamento está classificado como Crítico.

Neste caso, observa-se a presença de múltiplos fatores com coeficientes positivos e impacto contribuem significativamente para elevar o valor do *log-odds* (18,465), resultando em uma probabilidade estimada de inadimplência próxima de 100%.

A comparação entre os dois perfis hipotéticos evidencia a eficácia do modelo na distinção entre diferentes níveis de risco, com base em informações objetivas e mensuráveis. Tal capacidade reforça não apenas a robustez estatística do modelo, mas também sua aplicabilidade prática no contexto da análise de crédito.

A partir dessas estimativas, instituições financeiras ou empresas que operam com concessão de crédito podem estabelecer políticas mais assertivas de gestão de risco, segmentando clientes conforme o perfil de inadimplência projetado. Além disso, o modelo pode ser atualizado continuamente, à medida que novos dados são incorporados, favorecendo uma abordagem preditiva e dinâmica para a tomada de decisões (HAIR *et al.*, 2009; VIEIRA; RIBAS, 2011).

A aplicação prática do modelo desenvolvido possibilita à instituição financeira transformar as estimativas de probabilidade de inadimplência em um instrumento de gestão ativa da carteira. Ao rodar o modelo de forma recorrente — por exemplo, em bases quinzenais — a instituição obtém um retrato atualizado do risco de cada contrato, permitindo decisões tempestivas.

Na gestão da carteira, os contratos podem ser segmentados por faixas de risco (baixo, moderado, elevado) e vinculados a planos de ação diferenciados. Para contratos classificados como baixo risco, pode-se autorizar novos limites de crédito. Para contratos de risco intermediário, recomenda-se monitoramento mais próximo, com reforço de comunicação preventiva, revisão de limites e possível aumento no percentual dos recebíveis utilizados para amortização do crédito, como medida de proteção adicional. Já para contratos de alto risco, a instituição pode adotar contenção de novas concessões, renegociação preventiva, intensificação da retenção dos fluxos de cartão (por exemplo, elevar a alíquota de travamento de 20% para 40% do faturamento) e, em último caso, processo de saída planejada (encerramento de limite ou cobrança antecipada).

A rotação periódica do modelo permite também avaliar tendências agregadas: crescimento de risco em determinados setores, concentração geográfica de inadimplência ou alterações sazonais no comportamento de pagamento. Essa leitura orienta a política de crédito institucional, ajustando limites setoriais, critérios de concessão e indicadores de alerta.

Por ser um *score* dinâmico, o modelo se integra facilmente a sistemas automatizados, emitindo alertas quando há variação significativa no risco individual. Isso garante que o gestor

tenha subsídios objetivos para decidir conceder crédito adicional, manter o contrato inalterado ou reduzir a exposição, evitando decisões tardias e aumentando a eficiência operacional.

5 CONSIDERAÇÕES FINAIS

A presente pesquisa teve como objetivo desenvolver um modelo preditivo de inadimplência para uma Sociedade de Crédito Direto voltada ao financiamento de PMEs, utilizando regressão logística binária, com o propósito de estimar, de forma recorrente, a probabilidade de inadimplência dos clientes, subsidiando o monitoramento contínuo da carteira e a implementação de ações preventivas. A abordagem adotada considerou não apenas variáveis cadastrais, mas também dados comportamentais extraídos do relacionamento das empresas com a plataforma da instituição, viabilizando a construção de um *score* dinâmico voltado ao monitoramento do risco de crédito em tempo real.

Os resultados obtidos permitiram a avaliação das hipóteses formuladas no estudo. A hipótese nula (H_0), que sustentava que as variáveis cadastrais, contratuais e relacionadas ao comportamento financeiro e de interações recentes da empresa não têm efeito significativo na predição de inadimplência, foi rejeitada (teste de Omnibus com $p = < 0,001$). Isso demonstra que essas variáveis são essenciais para melhorar a capacidade preditiva do modelo e, conseqüentemente, o acompanhamento do risco de crédito.

Além disso, o modelo apresentou robustez estatística, com elevado poder preditivo e boa aderência aos dados. O *pseudo* R^2 de Nagelkerke de 0,962 evidencia a capacidade da regressão logística em discriminar com alta precisão os contratos com maior probabilidade de inadimplência. Variáveis como o percentual do saldo em aberto, a sinalização de risco “Crítico” no farol de pagamento e o status baixado do CNPJ mostraram-se altamente significativas, reafirmando a importância da atualização constante dos dados e da análise comportamental na concessão e no acompanhamento do crédito.

O uso do *score* dinâmico representa uma inovação relevante ao incorporar informações temporais no processo de avaliação, permitindo que a instituição ajuste rapidamente suas estratégias conforme as mudanças no perfil de risco dos tomadores de crédito. Essa abordagem é especialmente importante para o segmento de PMEs, caracterizado por maior volatilidade e especificidades próprias.

Como contribuição prática, o estudo propõe uma metodologia que pode ser incorporada por instituições financeiras em seus modelos de gestão de risco, promovendo maior eficácia na prevenção de perdas e no direcionamento de políticas de crédito mais seguras. Ademais, a flexibilidade do modelo possibilita atualizações frequentes, facilitando sua integração a sistemas automatizados de análise de risco.

Por fim, esta pesquisa contribui tanto para o avanço do conhecimento acadêmico quanto para a prática financeira, ao fornecer uma ferramenta robusta para o controle do risco de crédito em ambientes que utilizam garantias atreladas a recebíveis de cartão. Para estudos futuros, recomenda-se a inclusão de variáveis macroeconômicas, análise de sazonalidade e uso de métodos comparativos, como árvores de decisão e redes neurais, a fim de avaliar o desempenho relativo da regressão logística frente a outras técnicas preditivas.

REFERÊNCIAS

- AKKOÇ, S. An empirical comparison of conventional techniques, neural networks and the three stage hybrid Adaptive Neuro Fuzzy Inference System (ANFIS) model for credit scoring analysis: The case of Turkish credit card data. **European Journal of Operational Research**, v. 222, n. 1, p. 168–178, 2012. Disponível em: <https://doi.org/10.1016/j.ejor.2012.04.009>. Acesso em: 17 mar. 2025.
- ALBANESI, S.; VAMOSSAY, D. F. Predicting consumer default: A deep learning approach **Cornell University**, 2019. Disponível em: <https://arxiv.org/abs/1908.11498>. Acesso em: 05 abr. 2025.
- AMARAL, G. H. de O. Determinantes de inadimplência e de recuperação de crédito em um banco de desenvolvimento. **BASE - Revista de Administração e Contabilidade da Unisinos**, v. 17, n. 3, 2020. Disponível em: <https://www.redalyc.org/articulo.oa?id=337264550006>. Acesso em: 22 fev. 2025.
- ASSAF NETO, A. **Mercado financeiro**. 11. ed. São Paulo: Editora Atlas, 2012.
- AUDRETSCH, D. B. Innovation and industrial dynamics. *In*: DOSI, G.; MALERBA, F. (Eds.). **Innovation, organization and economic dynamics: Selected essays**. Cheltenham: Edward Elgar, 1999. p. 281–296.
- AZEREDO, V. C. de. Aplicação e análise da eficácia de modelos brasileiros de previsão de insolvência para empresas. 2019. Trabalho de Conclusão de Curso (Graduação em Administração) – **Universidade Federal de Santa Catarina**, Florianópolis, 2019. Disponível em: <https://repositorio.ufsc.br/handle/123456789/202719>. Acesso em: 29 mar. 2025.
- BANCO CENTRAL DO BRASIL. **Resolução nº 2.682**, de 22 de dezembro de 1999. 1999. Disponível em: https://www.bcb.gov.br/pre/normativos/res/1999/pdf/res_2682_v2_1.pdf. Acesso em: 02 fev. 2025.
- BANCO CENTRAL DO BRASIL. **Resolução nº 4.734**, de 27 de junho de 2019: Dispõe sobre as operações de crédito com garantia de recebíveis. 2019a. Disponível em: https://www.bcb.gov.br/pre/normativos/res/2019/pdf/res_4734_v1_O.pdf. Acesso em: 10 abr. 2025.
- BANCO CENTRAL DO BRASIL. **Circular nº 3.952**, de 28 de junho de 2019: Regulamenta os procedimentos operacionais das operações com garantia de recebíveis. 2019b. Disponível em: https://www.bcb.gov.br/pre/normativos/circ/2019/pdf/circ_3952_v1_O.pdf. Acesso em: 25 fev. 2025.
- BANCO CENTRAL DO BRASIL. **Relatório de Estabilidade Financeira**. abril 2025. Disponível em: <https://www.bcb.gov.br/content/publicacoes/ref/202504/RELESTAB202504-refPub.pdf>. Acesso em: 08 mai. 2025.
- BANK FOR INTERNATIONAL SETTLEMENTS. **Basileia II**: International convergence of capital measurement and capital standards: A revised framework. Basel Committee on Banking Supervision, 2006. Disponível em: <https://www.bis.org/publ/bcbs128.htm>. Acesso em: 15 mar. 2025.

- BESERRA, R. S. *et al.* Modelagem com regressão logística para análise de concessão de crédito. **Research, Society and Development**, v. 11, n. 7, e15211729761, 2022. Disponível em: <https://doi.org/10.33448/rsd-v11i7.29761>. Acesso em: 01 mai. 2025.
- BRITO, G. A. S.; ASSAF NETO, A. Modelo de classificação de risco de crédito de empresas. **Revista Contabilidade & Finanças**, v. 19, n. 46, p. 18-29, 2008. Disponível em: <https://doi.org/10.1590/S1519-70772008000100003>. Acesso em 12 mar. 2025.
- BÜCKER, M. *et al.* Transparency, auditability and explainability of machine learning models in credit scoring. **Cornell University**, 2020. Disponível em: <https://arxiv.org/abs/2009.13384>. Acesso em: 07 mar. 2025.
- CALDAS, F. C. P. O cenário de crédito e risco de inadimplência em fintechs no Brasil. 2020. Dissertação (Mestrado em Administração) – **Fundação Getúlio Vargas**, Rio de Janeiro, 2020. Disponível em: <https://hdl.handle.net/10438/29989>. Acesso em: 19 fev. 2025.
- CAMARGOS, M. A. de. *et al.* Fatores condicionantes de inadimplência em processos de concessão de crédito a micro e pequenas empresas do Estado de Minas Gerais. **Revista de Administração Contemporânea**, v. 14, n. 2, p. 333–352, 2010. Disponível em: <https://doi.org/10.1590/S1415-65552010000200009>. Acesso em: 11 abr. 2025.
- CARDOSO, D. D.; LIMA, N. C. Avaliação de risco na concessão de crédito por pessoa jurídica não financeira. **Revista Ambiente Contábil**, v. 16, n. 2, p. 117–139, 2024. Disponível em: <https://doi.org/10.21680/2176-9036.2024v16n2ID34315>. Acesso em: 03 mai. 2025.
- CEPAL. Inclusão financeira de pequenas e médias empresas no Brasil. **Comissão Econômica para a América Latina e o Caribe**, 2017. Disponível em: <https://www.cepal.org/pt-br/publicacoes/43229-inclusao-financeira-pequenas-medias-empresas-brasil>. Acesso em: 14 mar. 2025.
- CHANG, E. *et al.* The stability concentration relationship in the Brazilian banking system. **Journal of International Financial Markets, Institutions and Money**, v. 18, p. 388–397, 2008. Disponível em: https://www.bcb.gov.br/content/publicacoes/WorkingPaperSeries/wps145.pdf?utm_source. Acesso em 12 mar. 2025.
- CIAMPI, F.; GORDINI, N. Small enterprise default prediction modeling through artificial neural networks: An empirical analysis of Italian small enterprises. **Journal of Small Business Management**, v. 51, n. 1, p. 23–45, 2013. Disponível em: https://flore.unifi.it/handle/2158/656301?utm_source.com. Acesso em 12 mar. 2025.
- CNDL & SPC BRASIL. Inadimplência atinge 68,76 milhões de consumidores em fevereiro, aponta CNDL/SPC Brasil. **Confederação Nacional de Dirigentes Lojistas**, 2025. Disponível em: <https://cndl.org.br/varejosa/inadimplencia-atinge-6876-milhoes-de-consumidores-em-fevereiro-aponta-cndl-spc-brasil/>. Acesso em: 06 mai. 2025.
- COSTA, C. F. da. Análise da inadimplência das pessoas físicas no cartão de crédito em razão da crise financeira de 2015. 2016. Monografia (Especialização em Finanças) – **Universidade Federal do Paraná**, Curitiba, 2016. Disponível em: <https://acervodigital.ufpr.br/handle/1884/57286>. Acesso em: 28 fev. 2025.

DAHOOIE, J. H. *et al.* A novel dynamic credit risk evaluation method using data envelopment analysis with common weights and combination of multi-attribute decision-making methods. **Computers & Operations Research**, v. 129, 105223, 2021. Disponível em: <https://doi.org/10.1016/j.cor.2021.105223>. Acesso em: 09 mar. 2025.

FÜHR, F. *et al.* Proposição de modelos de previsão de risco de crédito para pequenas e médias empresas por meio da regressão logística. **Gestão & Regionalidade**, v. 38, n. 113, p. 197–218, 2022. Disponível em: https://seer.uscs.edu.br/index.php/revista_gestao/article/view/6996/3567. Acesso em: 18 abr. 2025.

FREIRE, P. **Educação e mudança**. Rio de Janeiro: Paz e Terra, 1979.

FUSTER, A. *et al.* Predictably unequal? The effects of machine learning on credit markets. **The Journal of Finance**, v. 74, n. 5, p. 2083–2122, 2019. Disponível em: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3072038&utm_source. Acesso em 12 mar. 2025.

GIL, A. C. *et al.* **Como elaborar projetos de pesquisa**. São Paulo: Atlas, 2002.

GIRÃO, A. P. P. Previsão de insolvência nas PME: O setor das empresas comercializadoras de materiais de construção. 2015. Dissertação (Mestrado em Gestão) – **Universidade de Coimbra**, Coimbra, 2015. Disponível em: <https://core.ac.uk/download/pdf/55609438.pdf>. Acesso em: 23 mar. 2025.

GOLBAYANI, P.; FLORESCU, I.; CHATTERJEE, R. A comparative study of forecasting corporate credit ratings using neural networks, support vector machines, and decision trees. **Cornell University**, 2020. Disponível em: <https://arxiv.org/abs/2007.06617>. Acesso em: 04 mai. 2025.

GOUVÊA, M. A.; GONÇALVES, E. B.; MANTOVANI, D. M. N. Análise de risco de crédito com aplicação de regressão logística e redes neurais. **Contabilidade Vista & Revista**, v. 24, n. 4, p. 96–123, 2015. Disponível em: <https://revistas.face.ufmg.br/index.php/contabilidadevistaerevista/article/view/1887>. Acesso em: 12 mar. 2025.

GOVERNO FEDERAL. **Boletim do Mapa de Empresas** – 3º quadrimestre de 2024. 2025. Disponível em: <https://www.gov.br/empresas-e-negocios/pt-br/mapa-de-empresas/boletins/boletim-do-mapa-de-empresas-3o-quad-2024.pdf>. Acesso em: 10 mai. 2025.

GROSS, D.; SOULELES, N. An empirical analysis of personal bankruptcy and delinquency. **Review of Financial Studies**, v. 15, n. 1, p. 319–347, 2002. Disponível em: https://academic.oup.com/rfs/article-abstract/15/1/319/1620343?redirectedFrom=fulltext&login=false&utm_source.com. Acesso em 12 mar. 2025.

GUIMARÃES, P. R. F.; RESENDE FILHO, M. A. Uma aplicação do modelo de regressão logística na previsão de falência empresarial no Brasil. **Revista Brasileira de Economia de Empresas**, v. 18, n. 2, p. 21–42, 2018. Disponível em: https://www.researchgate.net/publication/318661083_Uma_aplicacao_do_modelo_de_regressao_logistica_na_previsao_de_falencia_empresarial_no_Brasil. Acesso em 20 abr. 2025.

HAIR JR., J. F. *et al.* **Análise multivariada de dados**. Porto Alegre: Bookman, 2009.

HAJEK, P.; MICHALAK, K. Feature selection in corporate credit rating prediction.

Knowledge-Based Systems, v. 51, p. 72–84, 2013. Disponível em:

<https://doi.org/10.1016/j.knosys.2013.07.008>. Acesso em 20 abr. 2025.

HOSMER, D. W.; LEMESHOW, D. W. **Applied logistic regression**. New York: John Wiley & Sons, 1989.

HOUAISS, A.; VILLAR, M. de S. **Dicionário Houaiss da Língua Portuguesa**. Rio de Janeiro: Objetiva, 2001.

HUANG, Z. *et al.* Credit rating analysis with support vector machines and neural networks: A market comparative study. **Decision Support Systems**, v. 37, n. 4, p. 543–558, 2004.

Disponível em: [https://doi.org/10.1016/S0167-9236\(03\)00086-1](https://doi.org/10.1016/S0167-9236(03)00086-1). Acesso em 20 abr. 2025.

IFRS FOUNDATION. IFRS 9 – **Financial instruments**. 2014. Disponível em:

<https://www.ifrs.org/issued-standards/list-of-standards/ifrs-9-financial-instruments/>. Acesso em: 02 fev. 2025.

KASZNAR, I. K. Marketing, políticas de crédito e inadimplência: vender bem e evitar o mau pagador: um desafio permanente. **Revista Pensamento Contemporâneo em Administração**, v. 3, n. 2, 2009. Disponível em: <https://doi.org/10.12712/rpca.v3i2.11012>. Acesso em: 26 abr. 2025.

KAVUSSANOS, M. G.; TSOUKNIDIS, D. A. Default risk drivers in shipping bank loans.

Transportation Research Part E: **Logistics and Transportation Review**, v. 94, p. 71–94,

2016. Disponível em: <https://doi.org/10.1016/j.tre.2016.07.008>. Acesso em: 12 mar. 2025.

KOZENY, V. Genetic algorithms for credit scoring: Alternative fitness function performance comparison. **Expert Systems with Applications**, v. 42, n. 6, p. 2998–3004, 2015. Disponível em:

<https://doi.org/10.1016/j.eswa.2014.11.028>. Acesso em: 21 abr. 2025.

LI, K.; NISKANEN, J.; KOLEHMAINEN, M. Financial innovation credit default hybrid model for SME lending. **Expert Systems with Applications**, v. 61, p. 343–355, 2016.

Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0957417416302548>.

Acesso em 02 mar. 2025.

LOCATELLI, R. L. *et al.* Determinantes da inadimplência no crédito habitacional direcionado à classe média emergente brasileira. **Revista de Finanças Aplicadas**, v. 1, p. 1–30, 2015. Disponível em:

https://www.academia.edu/114702268/Determinantes_Da_Inadimpl%C3%Aancia_No_Cr%C3%A9dito_Habitacional_Direcionado_%C3%80_Classe_M%C3%A9dia_Emergente_Brasil. Acesso em 21 mar. 2025.

LOUZIS, D. P.; VOULDIS, A. T.; METAXAS, V. L. Macroeconomic and bank-specific determinants of non-performing loans in Greece: A comparative study of mortgage, business and consumer loan portfolios. **Journal of Banking & Finance**, v. 49, p. 258–272, 2015.

Disponível em <https://doi.org/10.1016/j.jbankfin.2011.10.012>. Acesso em 20 mar. 2025.

MACHADO, T. B.; RIBEIRO, A. M. Antecipação de recebíveis nos bancos vs factorings: uma análise das diferenças entre as taxas cobradas e suas possíveis causas. **Revista**

Catarinense da Ciência Contábil, v. 17, n. 51, p. 23–40, 2018. Disponível em: <https://revista.crcsc.org.br/index.php/CRCSC/article/view/2554>. Acesso em: 02 abr. 2025.

MCKINSEY & COMPANY. **O novo normal do crédito para PME: Desafios, tendências e inovações**. 2021. Disponível em: <https://www.mckinsey.com.br/our-insights/all-insights/ou-novo-normal-do-credito-para-pme>. Acesso em: 09 mar. 2025.

NAGELKERKE, N. J. D. A note on a general definition of the coefficient of determination. **Biometrika, Oxford**, v. 78, n. 3, p. 691–692, 1991. Disponível em: <https://doi.org/10.1093/biomet/78.3.691>. Acesso em 03 mar. 2025.

NUCLEA. **O papel dos recebíveis de cartões na redução de riscos de crédito**. 2025. Disponível em: <https://www.nuclea.com.br/papel-dos-recebiveis-de-cartoes-na-reducao-de-riscos-de-credito/>. Acesso em: 10 mar. 2025.

OLIVEIRA, J. C. T. *et al.* A inadimplência das empresas no Brasil e seus determinantes macroeconômicos. In: CONGRESSO UFPE DE CIÊNCIAS CONTÁBEIS, 1., 2015, Recife. **Anais [...]**. Recife: Universidade Federal de Pernambuco, 2015. Disponível em: <https://periodicos.ufpe.br/revistas/SUCC/article/view/2389>. Acesso em: 16 fev. 2025.

OLIVEIRA, L. F. L. A. Análise da evolução da inadimplência bancária em cenários de estresse através do uso de vetores autorregressivos. 2015. Trabalho de Conclusão de Curso (Graduação em Economia) – **Universidade Federal do Ceará**, Fortaleza, 2015. Disponível em: <https://repositorio.ufc.br/handle/riufc/15334>. Acesso em: 20 abr. 2025.

PROVENZANO, A. R. *et al.* Machine learning approach for credit scoring. **Cornell University**, 2020. Disponível em: <https://arxiv.org/abs/2008.01687>. Acesso em: 27 mar. 2025.

RODRIGUES, F. R. Modelos de previsão de falências e os fatores ESG nas empresas portuguesas. 2024. Dissertação (Mestrado em Contabilidade e Finanças) – **Universidade do Porto**, Porto, 2024. Disponível em: <https://repositorio-cientifico.up.pt/handle/10216/133669>. Acesso em: 14 abr. 2025.

ROGGI, O.; GIANNOZZI, A. IRB approach for SME portfolios. **Bancaria**, n.10. Disponível em: https://www.researchgate.net/publication/280077926_Building_Sme_rating_is_it_necessary_for_lenders_to_monitor_financial_statements_of_the_borrowers. Acesso em: 4 fev. 2025.

SANTOS, J.; FAMÁ, R. Avaliação da aplicabilidade de um modelo de credit scoring com variáveis sistêmicas e não-sistêmicas em carteiras de crédito bancário rotativo de pessoas físicas. **Revista Contabilidade e Finanças**, v. 18, n. 44, p. 105–117, 2007. Disponível em: <https://www.scielo.br/j/rcf/a/MrQGrCWSkLvJGtmRhkT8c5m/abstract/?lang=pt>. Acesso em 13 mar. 2025.

SCHIOZER, R.; YOSHIDA JR., V. Achatando a curva da inadimplência. **GV Executivo**, v. 19, n. 3, p. 20, 2020. Disponível em: <https://doi.org/10.12660/gvexec.v19n3.2020.81727>. Acesso em: 19 mar. 2025.

SECRETARIA DE COMUNICAÇÃO DA PRESIDÊNCIA DA REPÚBLICA. Brasil registra abertura de 1,4 milhão de pequenos negócios no primeiro trimestre do ano. **Governo do Brasil**, 2025. Disponível em: <https://www.gov.br/secom/pt->

br/assuntos/noticias/2025/04/brasil-registra-abertura-de-1-4-milhao-de-pequenos-negocios-no-primeiro-trimestre-do-ano. Acesso em: 05 mai. 2025.

SECURATO, J. R.; FAMÁ, R. Um procedimento para a decisão de crédito pelos bancos. **Revista de Administração Contemporânea**, v. 1, n. 1, p. 101–119, 1997. Disponível em: <https://doi.org/10.1590/S1415-65551997000100006>. Acesso em: 08 fev. 2025.

SEBRAE. **Confira os grandes números dos pequenos negócios no Brasil**. [s.d.]. Disponível em: <https://agenciasebrae.com.br/dados/confira-os-grandes-numeros-dos-pequenos-negocios-no-brasil/>. Acesso em: 12 fev. 2025.

SELAU, L. P. R.; RIBEIRO, J. L. D. Uma sistemática para construção e escolha de modelos de previsão de risco de crédito. **Gestão & Produção**, v. 15, n. 3, p. 481–495, 2008. Disponível em: <https://www.scielo.br/j/gp/a/FwwcC5DQhVqsnBNKZvprtBz>. Acesso em: 03 mar. 2025.

SERASA EXPERIAN. **Empreender Brasil: Inteligência de Mercado para PMEs**. [2025]. Disponível em: <https://www.serasaexperian.com.br>. Acesso em: 24 abr. 2025.

SHANG, Y.; DUNSON, D. B.; SONG, J.-S. Exploiting big data in logistics risk assessment via Bayesian nonparametrics. **Cornell University**, 2015. Disponível em: <https://arxiv.org/abs/1501.05349>. Acesso em: 13 fev. 2025.

SILVA, G. A.; ASSAF NETO, A.; CORRAR, L. J. Sistema de classificação de risco de crédito: uma aplicação a companhias abertas no Brasil. **Revista Contabilidade & Finanças**, v. 20, n. 50, p. 44–62, 2009. Disponível em: <https://doi.org/10.1590/S1519-70772009000300003>. Acesso em: 10 mar. 2025.

SILVA, S. F. P. da; PESSANHA, J. F. M. Identificação de indicadores para previsão de insolvência das distribuidoras de energia elétrica por meio de regressão logística para dados em painel. **Contabilometria – Brazilian Journal of Quantitative Methods Applied to Accounting**, v. 9, n. 1, p. 73–91, 2022.

VIEIRA, P. R. da C.; RIBAS, J. R. **Análise multivariada com uso do SPSS**. Rio de Janeiro: Editora Ciência Moderna Ltda., 2011.

VILLELA, L. M.; PINTO, J. D. S.; DINIZ, E. C. Que fatores determinam o nível de endividamento das pequenas e médias empresas no Brasil? *In*: CONGRESSO DE ADMINISTRAÇÃO, SOCIEDADE E INOVAÇÃO – CASI 2016, 2016, Juiz de Fora. **Anais** [...]. Juiz de Fora: Universidade Federal de Juiz de Fora, 2016. Disponível em: <https://www.even3.com.br/anais/casi/36804-QUE-FATORES-DETERMINAM-O-NIVEL-DE-ENDIVIDAMENTO-DAS-PEQUENAS-E-MEDIAS-EMPRESAS-NO-BRASIL>. Acesso em: 06 fev. 2025.

ZHU, Y.; LI, X.; ZHANG, Y. Predicting China's SME credit risk in supply chain financing by logistic regression, artificial neural network and hybrid models. **Sustainability**, v. 8, n. 5, p. 1–17, 2016. Disponível em: <https://www.mdpi.com/2071-1050/8/5/433>. Acesso em 17 Mar. 2025.