

FACULDADE FIPECAFI

**PROGRAMA DE MESTRADO PROFISSIONAL
EM CONTROLADORIA E FINANÇAS**

FLÁVIO RICARDO DE SOUZA ANDRADE LIMA JÚNIOR

*Análise do impacto do uso de ferramentas de **Data Analytics** nas áreas de Crédito e
Cobrança*

SÃO PAULO

2025

FACULDADE FIPECAFI

**PROGRAMA DE MESTRADO PROFISSIONAL
EM CONTROLADORIA E FINANÇAS**

FLÁVIO RICARDO DE SOUZA ANDRADE LIMA JÚNIOR

**Análise do impacto do uso de ferramentas de *Data Analytics* nas áreas de Crédito e
Cobrança**

Projeto de pesquisa apresentado ao Curso de Mestrado Profissional em Controladoria e Finanças da Faculdade FIPECAFI para a obtenção do título de Mestre Profissional em Controladoria e Finanças.

Orientadora: Profa. Dra. Sonia Rosa Arbues Decoster

SÃO PAULO

2025

FACULDADE FIPECAFI

Prof. Dr. Welington Rocha

Diretor Presidente

Prof. Dr. Fernando Dal-Ri Murcia

Diretor de Pesquisa

Profa. Dra. Eliana Rodrigues

Diretora de Cursos

Prof. Dr. Paschoal Tadeu Russo

Coordenador do Curso de Mestrado Profissional em Controladoria e Finanças

Catálogo na publicação

Serviço de Biblioteca da Faculdade FIPECAFI

Fundação Instituto de Pesquisas Contábeis Atuárias e Financeiras (FIPECAFI)

Dados fornecidos pelo (a) autor (a)

L732a Lima Júnior, Flávio Ricardo de Souza Andrade.

Análise do impacto do uso de ferramentas de Data Analytics nas áreas de crédito e cobrança. / Flávio Ricardo de Souza Andrade Lima Júnior. -- São Paulo, 2025.

97 p. il.

Dissertação (Mestrado Profissional) - Programa de Mestrado Profissional em Controladoria e Finanças – Faculdade FIPECAFI Fundação Instituto de Pesquisas Contábeis Atuárias e Financeiras

Orientador: Profa. Dr.^a Sonia Rosa Arbues Decoster.

1. Data Analytics. 2. Gestão financeira. 3. Crédito e cobrança. 4. Tomada de decisão. 5. Transformação digital. I. Profa. Dr.^a Sonia Rosa Arbues Decoster.

657.07

FLÁVIO RICARDO DE SOUZA ANDRADE LIMA JÚNIOR

Análise do impacto do uso de ferramentas de *Data Analytics* no Crédito e Cobrança

Dissertação de Mestrado apresentada ao Curso de Mestrado Profissional em Controladoria e Finanças da Faculdade FIPECAFI, para a obtenção do título de Mestre Profissional em Controladoria e Finanças.

Aprovado em: 14/08/2025

Prof. Dra. Sonia Rosa Arbues Decoster
Faculdade FIPECAFI
Professor Orientador – Presidente da Banca Examinadora

Prof. Dr. Paschoal Tadeu Russo
Faculdade FIPECAFI
Membro Interno

Prof. Dr. Durval Lucas dos Santos Júnior
Unifesp - Universidade Federal de São Paulo
Membro Externo

SÃO PAULO

2025

RESUMO

Lima Júnior, F. R. S A. (2025). *Análise do impacto do uso de ferramentas de Data Analytics nas áreas de Crédito e Cobrança* (Dissertação de Mestrado). Faculdade FIPECAFI, São Paulo, SP, Brasil.

A dissertação tem como objetivo principal a investigação do impacto do uso de ferramentas de *Data Analytics* na gestão financeira, com foco nas áreas de crédito e cobrança, em uma distribuidora de acumuladores elétricos, possibilitando maior agilidade na tomada de decisão, segmentações mais precisas de clientes e controle mais efetivo dos indicadores de inadimplência. A pesquisa parte da observação de um contexto em que empresas buscam respostas mais rápidas e assertivas frente à crescente complexidade dos mercados e à necessidade de decisões baseadas em dados. O estudo apresenta a metodologia da pesquisa-ação, sustentada por triangulação de dados quantitativos e qualitativos. O trabalho discute como os profissionais da área incorporaram o uso de painéis dinâmicos, algoritmos preditivos e relatórios customizáveis para análise de risco, concessão de crédito e gestão de inadimplência. A investigação considera a experiência prática de gestores financeiros, suas equipes operacionais e busca compreender de que forma as ferramentas de *Data Analytics* têm transformado a rotina operacional e o processo decisório, promovendo maior integração entre dados históricos e projeções futuras. O estudo também analisa a percepção dos gestores quanto aos desafios enfrentados na implementação dessas soluções, destacando fatores como a qualidade da base de dados e o domínio técnico das ferramentas. Além disso, a pesquisa identifica os principais indicadores utilizados para monitorar o desempenho das áreas de crédito e cobrança, bem como os benefícios observados após a integração do *Data Analytics* nesses processos. Os resultados mostram redução média de 17,79% nos índices de inadimplência do grupo de intervenção, diminuição consistente do Prazo Médio de Recebimento (PMR) e ganho de agilidade na análise de crédito, que passou de horas para minutos. A robustez dos achados foi confirmada por testes estatísticos de alta relevância ($p < 0,0001$), reforçando a eficácia da intervenção. Além dos benefícios quantitativos, a pesquisa destacou que as ferramentas de *data analytics* propiciaram um aprimoramento da capacidade dos gestores financeiros em tomar decisões estratégicas mais assertivas, as ferramentas proporcionaram ganhos significativos de eficiência operacional, reduzindo drasticamente o tempo de análise de crédito e otimizando a priorização dos clientes na cobrança, como também enfatizou a eficiência na redução da inadimplência. Conclui-se que o uso estratégico de *Data Analytics* fortalece o papel da controladoria em um ambiente digital e competitivo, promovendo maior eficiência, confiabilidade e alinhamento entre objetivos corporativos e comportamento dos clientes. O trabalho conclui que a utilização de ferramentas analíticas proporciona maior eficiência e confiabilidade na gestão financeira, tornando possível alinhar os objetivos corporativos ao comportamento de clientes e à realidade do mercado. Dessa forma, o estudo amplia a discussão sobre inovação na controladoria e oferece subsídios para o desenvolvimento de práticas mais inteligentes, baseadas em evidências e orientadas por dados.

Palavras-chave: *Data Analytics*, Gestão Financeira, Crédito e Cobrança, Tomada de Decisão, Transformação Digital.

ABSTRACT

Lima Júnior, F. R. S A. (2025). *Analysis of the Impact of Data Analytics Tools Usage in Credit and Collections* (Dissertação de Mestrado). Faculdade FIPECAFI, São Paulo, SP, Brasil.

The main objective of this dissertation is to investigate the impact of using Data Analytics tools in financial management, with a focus on the areas of credit and collections, within an electric accumulator distribution company. The study highlights how these tools enable greater agility in decision-making, more accurate customer segmentation, and more effective control of delinquency indicators. The research stems from observing a context in which companies seek faster and more assertive responses in the face of increasing market complexity and the growing need for data-driven decision-making. The study applies the action-research methodology, supported by the triangulation of quantitative and qualitative data. It discusses how professionals in the field have incorporated the use of dynamic dashboards, predictive algorithms, and customizable reports for risk analysis, credit granting, and delinquency management. The investigation takes into account the practical experience of financial managers and their operational teams, aiming to understand how Data Analytics tools have transformed operational routines and the decision-making process, fostering greater integration between historical data and future projections. The study also examines managers' perceptions regarding the challenges faced in implementing these solutions, emphasizing factors such as data quality and technical expertise with the tools. In addition, the research identifies the key indicators used to monitor the performance of credit and collections areas, as well as the benefits observed after the integration of Data Analytics into these processes. The results show an average 17.79% reduction in delinquency rates in the intervention group, a consistent decrease in the Average Collection Period (ACP), and significant time savings in credit analysis, which dropped from hours to minutes. The robustness of these findings was confirmed by highly relevant statistical tests ($p < 0.0001$), reinforcing the effectiveness of the intervention. Beyond quantitative benefits, the research highlighted that Data Analytics tools enhanced the ability of financial managers to make more assertive strategic decisions. They provided significant operational efficiency gains, drastically reducing credit analysis time and optimizing customer prioritization in collections, while also emphasizing efficiency in reducing delinquency. The study concludes that the strategic use of Data Analytics strengthens the role of controllership in a digital and competitive environment, fostering greater efficiency, reliability, and alignment between corporate objectives and customer behavior. It further asserts that the adoption of analytical tools enables higher efficiency and reliability in financial management, making it possible to align corporate goals with customer behavior and market realities. In this way, the research broadens the discussion on innovation in controllership and offers insights to support the development of smarter, evidence-based, and data-driven practices.

Keywords: *Data Analytics*, Financial Management, Credit and Collections, Decision-Making, Digital Transformation.

SUMÁRIO

1 INTRODUÇÃO.....	10
1.1 Contextualização.....	10
1.2 Problema e Objetivos de pesquisa	11
1.3 Objetivo Geral	11
1.4 Objetivos específicos	12
1.5 Justificativas.....	12
2. REVISÃO BIBLIOGRÁFICA	14
2.1. O surgimento do conceito Data Analytics.....	14
2.1.1 Dados estruturados e dados não estruturados	17
2.2 Ferramentas de Data Analytics.....	18
2.3 Categorias de mineração de dados e de aprendizado de máquina.....	18
2.3.1 Aprendizado de máquina	19
2.3.1.1. Algoritmos de classificação.....	20
2.3.1.2. Algoritmos de Associação ou Clustering.....	20
2.3.1.3. Regressão logística binária.....	21
2.3.1.4. Séries Temporais	21
2.3.1.5 Regressão Linear Múltipla.....	21
2.3.1.6 Máquinas de Vetores de Suporte - SVM.....	21
2.3.1.7 Análise de Cluster - K – Means.....	22
2.4 Gestão financeira.....	22
2.4.1. O planejamento financeiro.....	22
2.4.2. A análise financeira.....	23
2.4.3. A gestão do capital de giro.....	23
2.4.4. A gestão do risco financeiro	23
2.5 O uso da tecnologia nas áreas de contabilidade e finanças	24
2.5.1 A utilização de ferramentas de Data Analytics na Contabilidade.....	25
2.5.2 A utilização de ferramentas de Data Analytics na Gestão Financeira	25
2.5.3. A utilização de Data Analytics no monitoramento do Desempenho Financeiro	26
2.5.4. A utilização de ferramentas de Data Analytics no Crédito e Cobrança	26
2.5.5. Desafios relativos à implementação das ferramentas de Data Analytics.....	27
2.6. Proposições de Pesquisa.....	27
2.6.1. Sumário das Proposições de Pesquisa	29
3. MÉTODOS.....	30
3.1 Coleta de dados.....	32
3.1.1 Questionário para colaboradores	33
3.1.2 Formulários de entrevista.....	34
3.2. Análise de dados	35
3.3. Empresa Alfa.....	36
3.4. Reconhecimento	36
3.4.1. Reconhecimento da situação – Processo de cobrança.....	36
3.4.2. Reconhecimento da situação – Processo de Crédito	37

3.4.3. Reconhecimento da situação – Participantes	37
3.4.3.1 Tempo de serviço dos participantes na organização.....	37
3.4.4. Reconhecimento das práticas profissionais atuais – Processo de cobrança	37
3.4.5. Reconhecimento das práticas profissionais atuais – Concessão de crédito.....	39
3.5 Reconhecimento da Intencionalidade	39
3.6 Planejamento.....	40
3.6.1 Amostra considerada para as etapas pré e pós-intervenção.....	40
3.6.2. Métricas a serem comparados nas etapas pré e pós intervenção.....	43
3.7 Implementação dos modelos de Data Analytics.....	43
3.7.1 Estimação do modelo – Risco de inadimplência	43
3.7.2. Estimação do modelo – Classificação de riscos de contas a receber.....	46
3.7.2.1. Árvore de decisão.....	46
3.7.2.2. Regressão Logística Binária.....	46
3.7.2.3. SVM (Support Vector Machine)	47
3.7.3 Métricas utilizadas na avaliação dos modelos.....	47
3.7.4 Painel desenvolvido no Power BI.....	48
3.7.5. Estimação do modelo – Limite de crédito.....	49
3.7.5.1 Árvore de Decisão.....	51
3.7.5.2 Regressão Logística Binária.....	51
3.7.5.3 SVM (Support Vector Machine)	52
3.7.6. Treinamento no uso das ferramentas.....	53
4. RESULTADOS	54
4.1 Apresentação e análise dos dados quantitativos	54
4.1.1. Análise de PMR Antes da Implementação	54
4.1.2. Análise da Inadimplência Antes da Implementação	56
4.1.2.1. Variabilidade dos Dados	56
4.1.3. Análise do PMR Após Implementação.....	57
4.1.4. Análise do Inadimplência Após implementação.....	58
4.1.5 Resultados a partir da Análise da Variância (ANOVA).....	59
5 AVALIAÇÃO.....	59
5.1. Avaliação do PMR.....	60
5.1.1. Análise comparativa de dados de PMR após implementação.....	60
5.1.2 Resultados de PMR do grupo sem intervenção.....	61
5.1.3 Comparação de PMR do Pós-intervenção x Pré-intervenção	62
5.2. Avaliação da Inadimplência.....	64
5.2.2. Resultados de Inadimplência do grupo sem intervenção	65
5.2.3. Comparação de Inadimplência do Pós-intervenção x Pré-intervenção.....	66
5.3 Avaliação dos colaboradores sobre ferramentas utilizadas	68
5.3.1. Eficiência na Prioridade de Cobrança (Painel Power BI).....	69
5.3.2. Redução do Tempo na Análise de Crédito (Algoritmo Automatizado).....	69
5.3.3. Acesso Facilitado a Informações Atualizadas (Dashboards Power BI)	69
5.3.4. Redução da Inadimplência com Apoio das Ferramentas	69
5.3.5. Adaptação das Ferramentas aos Processos Existentes	69
5.3.6. Recomendação para Expansão das Ferramentas.....	69

5.4 Avaliação das entrevistas dos gestores mediante às proposições	70
5.4.1 Capacidade de decisão estratégica na gestão do crédito e cobrança	70
5.4.2 Melhorias na eficiência na análise de crédito e priorização de clientes na cobrança	72
5.4.2.1 Melhorias na segmentação de clientes.....	73
5.4.3 Identificação de padrões com vistas à redução de inadimplência e à melhoria do fluxo de caixa nas organizações.....	74
5.5. Avaliação conjunta das proposições de pesquisa.....	76
6. CONCLUSÃO.....	77
6.1 Limitações de Pesquisa	79
6.2 Recomendações de Trabalhos Futuros	80
REFERÊNCIAS.....	81
GLOSSÁRIO	95

1. INTRODUÇÃO

1.1 Contextualização

Conforme uma pesquisa realizada pela Ernest & Young (2023), a transformação digital tem revolucionado diversos setores ao integrar tecnologias como inteligência artificial, *analytics* e computação em nuvem, proporcionando melhorias significativas na experiência do cliente e na eficiência operacional. Um estudo desenvolvido pela Deloitte (2023) explora como a análise de dados, capaz de criar conteúdo original com base em dados de treinamento, está transformando processos empresariais em diversos setores, incluindo serviços financeiros, saúde, varejo, tecnologia e educação.

Seguindo essa linha, o avanço tecnológico e o surgimento de grandes volumes de dados têm transformado as práticas de gestão financeira. E, nesse contexto, o uso de ferramentas de *Data Analytics* pode ser utilizado como uma poderosa ferramenta na tomada de decisões estratégicas e na obtenção de informações significativas para a gestão financeira, sobretudo quando se analisa um grande volume de dados, quando há necessidade de ter respostas rápidas, quando é preciso de dados verificáveis e diversidade de dados (Serasa Experian, 2025).

Para alcançar esse objetivo, essas empresas têm investido significativamente em componentes tecnológicos, como ambientes de dados estruturados e não estruturados, aplicações de modelagem estatística e de aprendizado de máquina, ferramentas de visualização de dados, entre outros. Como resultado, passaram a acumular grandes volumes de dados, que são integrados às suas funções de negócio para apoiar a tomada de decisões (Davenport, 2012). O uso de ferramentas eficientes para a correta coleta e análise dos dados financeiros do negócio, como, por exemplo, os indicadores de desempenho, o uso mostra-se essencial para o sucesso empresarial, pois permite as organizações uma visão ampla da organização (Colleoni, 2021).

Uma das principais problemáticas enfrentadas pelos gestores financeiros é a necessidade de obter informações em tempo real para uma análise precisa e atualizada do desempenho financeiro da organização. Com o uso de ferramentas de *Big Data*, é possível coletar e processar dados em tempo real, permitindo que os gestores tenham acesso a informações atualizadas e possam tomar decisões mais embasadas e ágeis (Hasan, Hoque & Le, 2023).

No cenário econômico atual e velocidade em que as coisas mudam, faz-se necessário que as empresas tenham uma gestão financeira ágil, com respostas quase em tempo real à medida em que as coisas acontecem. Maximizar o uso de dados internos e externos pode colocar a empresa em uma posição vantajosa, estimular novos negócios e descobrir novas oportunidades (Setty & Bakhshi, 2013). Silva (2019) descreve que *Data Analytics* consiste na existência de uma massa de dados tão volumosa que não pode ser analisada usando sistemas de gestão de base de dados ou programas de software tradicionais.

O *Data Analytics* possibilita uma análise mais profunda e detalhada dos dados, permitindo a identificação de tendências de mercado, comportamento do consumidor, padrões de compra, inadimplência e outras percepções relevantes para a gestão financeira. Isso auxilia os gestores na elaboração de estratégias mais precisas e direcionadas, tanto para redução de custos quanto para identificação de oportunidades de crescimento e aumento da lucratividade (McAfee e Brynjolfsson 2012).

É fundamental para os profissionais de finanças o conhecimento nas ferramentas de *analytics*. Para as áreas de Controladoria, Finanças e FP&A que possuem, dentre suas principais funções, a responsabilidade pela divulgação de informações seguras e acuradas para a tomada de decisão, o domínio e a utilização de ferramentas de *Data & Analytics* demonstram serem importantes para essa nova onda de tecnologia (Oliveira, Santos & Decoster, 2022).

1.2 Problema e Objetivos de pesquisa

A gestão do departamento financeiro de qualquer empresa tem grandes desafios sobretudo pelo dinamismo e complexidade dos dias atuais. Dentre esses desafios destacam-se: identificar e mitigar riscos financeiros, gerenciar contas a pagar e a receber, tomar decisões financeiras estratégicas, adaptar-se às mudanças do mercado, gestão de fluxo de caixa, entre outros. Há de se destacar que o cenário econômico indica um crescimento nas dívidas e inadimplência. De acordo com a Pesquisa de Endividamento e Inadimplência do Consumidor, divulgada pela CNC (Confederação Nacional do Comércio de Bens, Serviços e Turismo), em setembro de 2022, o total de lares brasileiros com dívidas a vencer chegou a 79,30%, o terceiro aumento consecutivo em 2022. De acordo com a mesma pesquisa, o endividamento dos carnês está em 18,80% (Confederação Nacional do Comércio de Bens, Serviços e Turismo 2022).

Oliveira e Santos (2022) alertam que a inadimplência pode desencadear crises com efeitos em cascata, prejudicando não só instituições financeiras, mas mercados inteiros. Essa preocupação é especialmente relevante para o Brasil, onde o sistema financeiro enfrenta desafios significativos na gestão do risco de crédito, exigindo decisões mais acuradas e baseadas em dados.

Modelos de análise tradicionais, como regressões logísticas, frequentemente se restringem a variáveis financeiras e pressupõem relações lineares entre elas. Isso, de acordo com Zöllner e Huber (2021), dificulta a adaptação a contextos mais complexos. Além de aprimorar a análise de risco, a incorporação de modelos de aprendizado de máquina busca melhorar a transparência e a conformidade regulatória.

Segundo Junqueira (2018), realizar a gestão financeira é uma das principais atividades do negócio, afinal é por meio dos indicadores financeiros que o gestor tomará ciência da situação em que a empresa se encontra, e conseguirá traçar estratégias para atingir os objetivos a que se propôs. Para lidar com esses desafios, o uso de ferramentas de *Data Analytics* tem se mostrado uma abordagem promissora, fornecendo novas perspectivas para a tomada de decisões financeiras embasadas em dados.

Com o *Data Analytics*, que lida com grandes volumes de dados provenientes de diversas fontes, é crucial garantir a qualidade e a consistência dos dados para evitar decisões equivocadas. Nesse sentido, a verificação e a limpeza dos dados são processos essenciais para garantir a confiabilidade das análises financeiras (Chen et al., 2012).

A gestão de grandes volumes de dados requer uma infraestrutura tecnológica *robusta* e escalável. É fundamental ter sistemas de armazenamento e processamento de dados adequados, além de recursos de hardware e software capazes de lidar com a quantidade e a complexidade dos dados financeiros. A falta de uma infraestrutura adequada pode limitar a eficácia do uso de *Data Analytics* na gestão financeira (Davenport, 2014).

Diante do acima exposto chega-se à seguinte questão de pesquisa: **Qual é o impacto do uso de ferramentas de *Data Analytics* no setor específico da área de crédito e cobrança em uma distribuidora de acumuladores elétricos?**

1.3 Objetivo Geral

O objetivo geral deste estudo é investigar o impacto do uso de ferramentas de *Data Analytics* no setor específico da área de crédito e cobrança de uma distribuidora de acumuladores elétricos com abrangência nacional, com base na comparação de dados históricos e pós-implementação destas ferramentas. Por meio da análise e avaliação de performance das empresas que foram implementadas com ferramentas e técnicas de *Data Analytics*, busca-se compreender como o emprego dessas ferramentas pode influenciar e aprimorar as atividades financeiras da empresa. Serão explorados os benefícios potenciais, tais como a melhora nos indicadores financeiros, otimização do uso de pessoas, redução de inadimplência, identificação de oportunidades de negócio e tomada de decisões mais embasadas. Além disso, serão examinados os desafios e as limitações relacionadas à implementação de ferramentas de *Data Analytics* na gestão financeira, bem como as medidas necessárias para mitigar riscos e maximizar os resultados obtidos.

1.4 Objetivos específicos

Para que o seguimento dessa pesquisa seja viabilizado, colocaram-se os seguintes objetivos específicos:

- a) Analisar o processo da área de crédito e cobrança, identificando as principais necessidades e desafios enfrentados pela empresa nesse contexto;
- b) Identificar as ferramentas de *Data Analytics* mais relevantes para a gestão das áreas de crédito e cobrança, considerando aspectos como custo, acessibilidade e compatibilidade com as tecnologias utilizadas pela empresa;
- c) Implementar as ferramentas identificadas nos passos de análise e identificação dos processos;
- d) Realizar uma intervenção para avaliar o impacto do uso das ferramentas de *Data Analytics*, comparando indicadores financeiros antes e depois da implementação das novas tecnologias;
- e) Definir indicadores financeiros para avaliação de avaliação de performance;
- f) Propor recomendações para a gestão financeira com base nos resultados obtidos na intervenção, levando em conta as limitações e oportunidades identificadas durante a pesquisa;

1.5 Justificativas

Hoje, o principal desafio das empresas líderes de mercado é tomar decisões em tempo hábil, com base em informações essenciais e relevantes disponíveis no mercado. No entanto, com a grande quantidade de dados gerados pelas organizações, a análise desses dados se torna cada vez mais complexa, pois muitas vezes essas fontes precisam ser estruturadas, tratadas e entregues rapidamente. Esses fatores geraram a necessidade de desenvolver plataformas de inteligência de negócios (Xu et al., 2007).

Com o avanço das ferramentas de *Data Analytics*, a gestão financeira se beneficia de processos mais precisos e rápidos, favorecendo uma tomada de decisão mais eficiente. Segundo um estudo de Roberts e Taylor (2022), o uso de *analytics* não só aumenta a eficiência, mas também melhora a capacidade de identificar fraudes financeiras, uma necessidade crescente diante de transações cada vez mais complexas no mercado financeiro. Eles observam que o uso de algoritmos preditivos permite uma auditoria mais robusta, reduzindo a incidência de crimes financeiros graças ao monitoramento constante e em tempo real das operações financeiras, além de proporcionar maior transparência no cumprimento das normas regulatórias (Wharton, 2022).

A democratização do acesso a informações financeiras, facilitada por *Data Analytics*, também desempenha um papel crucial na inclusão financeira (Bello, 2024). Ferramentas de análise permitem que pequenos investidores e empresas acessem dados que anteriormente eram limitados a grandes instituições financeiras. Isso promove uma alocação mais equitativa de oportunidades, permitindo que mais indivíduos e organizações participem de forma significativa no mercado financeiro (Mhlanga, 2024).

A utilização de ferramentas de *Data Analytics* na gestão financeira resulta em uma redução nas despesas operacionais. Estudos, como o de Ward e Barker (2013), têm enfatizado a capacidade do *Data Analytics* de fornecer informações detalhadas que permitem uma melhor gestão dos recursos financeiros das organizações. Além disso, a pesquisa de Ahmed et al. (2016) destaca a importância de uma abordagem inclusiva na pesquisa de *Data Analytics*, considerando diferentes aspectos relacionados às despesas operacionais e às possíveis economias que podem ser alcançadas com o uso eficaz dessas ferramentas.

Ferramentas como *machine learning* permitem que as instituições financeiras criem modelos preditivos capazes de antecipar tendências do mercado e riscos econômicos, facilitando estratégias de mitigação de riscos e otimizando a alocação de recursos financeiros de forma mais confiável (McAfee & Brynjolfsson, 2012).

A adoção de *Data Analytics* na gestão financeira também favorece a conformidade regulatória. Em um contexto de regulação rigorosa e crescente, as instituições financeiras precisam

de ferramentas que possibilitem uma auditoria eficaz e contínua de suas operações. Ferramentas analíticas avançadas não apenas ajudam a identificar desvios, mas também criam uma trilha de auditoria que facilita a comprovação de conformidade com os órgãos reguladores (Grant Thornton, 2023).

Outro aspecto essencial dessas ferramentas é a capacidade de ampliar o acesso ao crédito e a produtos financeiros para consumidores e pequenas empresas. Esse tipo de inclusão financeira é mencionado por estudiosos, que relatam que a democratização do acesso a dados financeiros impulsionada pelo *Data Analytics* ajuda na expansão de serviços financeiros para camadas mais amplas da população, promovendo um ambiente financeiro mais inclusivo e transparente (Bello, 2024). O impacto positivo de *Data Analytics* na governança corporativa também é significativo. Em estudos recentes, Zoubi (2023) identifica que as ferramentas de análise avançada auxiliam na conformidade com regulamentações ambientais, sociais e de governança (ESG), facilitando o rastreamento do compromisso das empresas com práticas sustentáveis. Essa transparência regulatória é especialmente importante para os investidores, que estão cada vez mais interessados em avaliar empresas que demonstrem compromisso com práticas responsáveis e transparentes (Zoubi, 2023).

A utilização de ferramentas de *Data Analytics* na gestão financeira resultou em melhorias na eficiência. Estudos como o de McAfee e Brynjolfsson (2012) têm ressaltado a capacidade do *Data Analytics* de transformar a maneira como as empresas tomam decisões estratégicas. A análise de *Data Analytics* fornece dados detalhados sobre os processos financeiros, permitindo uma gestão mais eficiente dos recursos e uma alocação mais precisa dos investimentos.

As ferramentas de *Data Analytics* na gestão financeira resultam em aumento na lucratividade da empresa. Chen, Chiang e Storey (2012) destacam como a análise de *Data Analytics* pode fornecer contribuições relevantes sobre o mercado, os clientes e as tendências financeiras, permitindo uma melhor tomada de decisões e, conseqüentemente, um aumento na lucratividade. Além disso, a pesquisa de Altman, Marco e Varetto (1994) analisa a aplicação de técnicas como análise discriminante linear e redes neurais na identificação de empresas em situação de dificuldade financeira, demonstrando como a análise de *Data Analytics* pode contribuir para a identificação precoce de riscos financeiros e a preservação da lucratividade.

O uso de *Data Analytics* na gestão financeira resulta em uma melhoria na identificação de padrões. Estudos como o de Shen, Lin e Zhang (2015) exploram o uso de redes neurais de retropropagação para prever índices de ações, evidenciando a capacidade do *Data Analytics* de identificar e explorar padrões complexos nos dados financeiros. Adicionalmente, a pesquisa de Ahmed et al. (2016) destaca a importância de uma agenda de pesquisa inclusiva no campo do *Data Analytics*, que permita a exploração de diferentes técnicas e abordagens para identificar e entender os padrões ocultos nos dados financeiros. Aliado a isso a utilização de ferramentas de *Data Analytics* na gestão financeira resultou em uma melhoria na identificação de tendências.

McAfee e Brynjolfsson (2012) destacam como o *Data Analytics* pode fornecer compreensão sobre as tendências do mercado e do setor financeiro, permitindo que as empresas se adaptem rapidamente às mudanças e se posicionem estrategicamente. Além disso, Ward e Barker (2013) discutem diferentes definições de *Data Analytics* e suas implicações, fornecendo uma base conceitual sólida para entender como a identificação de tendências é fundamental para a gestão financeira.

Outro estudo relevante é o de Kim e Lee (2017), que destaca a influência das capacidades analíticas de *Data Analytics* no desempenho organizacional. Ao utilizar técnicas avançadas de análise de dados, como mineração de dados e modelagem preditiva, as empresas podem identificar tendências ocultas nos dados financeiros e tomar decisões mais informadas. Isso inclui a identificação de tendências de mercado, comportamento do consumidor, variações sazonais e até mesmo fatores macroeconômicos que afetam os negócios.

Sendo assim, este trabalho visa agregar valor à comunidade acadêmica e profissional ao ilustrar como a aplicação de ferramentas de Análise de Dados pode revolucionar a administração

financeira. Em um contexto em que as empresas lidam com desafios cada vez maiores ligados à complexidade dos dados e à demanda por decisões ágeis e exatas, o *Data Analytics* se apresenta como uma resposta crucial (UCEFF, 2024).

2. REVISÃO BIBLIOGRÁFICA

2.1. O surgimento do conceito Data Analytics

Impulsionada pelo surgimento do *Data Analytics*, a era da informação teve início nas últimas décadas, marcando uma revolução na forma como a informação é gerada, armazenada e processada. O crescimento exponencial da disponibilidade de dados foi motivado por avanços tecnológicos, como a expansão da internet, o desenvolvimento de dispositivos móveis e a proliferação de sensores conectados. Estudos como o de Hilbert e López (2011) destacam as etapas da era da informação, desde a coleta até a análise dos dados, evidenciando sua importância.

Nessa perspectiva, Caliandro e Graham (2020) destacam que a primeira etapa consiste na coleta maciça de dados provenientes de diversas fontes, como redes sociais, transações comerciais, sensores e dispositivos móveis. A disponibilidade e acessibilidade dessas fontes são fundamentais para a construção de conjuntos de dados abrangentes e diversificados. Após a coleta, a etapa de armazenamento desempenha um papel crucial no gerenciamento desses dados volumosos. A infraestrutura e os sistemas de gerenciamento de dados escaláveis são necessários para garantir a eficiência na organização e preservação dessas informações (Hilbert & López, 2011). Soluções como bancos de dados distribuídos e tecnologias de armazenamento em nuvem são comumente adotadas para enfrentar esse desafio.

Uma vez que os dados estão coletados e armazenados, a etapa de processamento e análise torna-se essencial para a descoberta de informações relevantes. Algoritmos avançados, como aprendizado de máquina e mineração de dados, são aplicados para descobrir padrões, identificar correlações e realizar previsões a partir dos conjuntos de dados, permitindo que as organizações tomem decisões mais informadas e estratégicas (Manyika et al., 2011). Por fim, a etapa de visualização e interpretação dos dados desempenha um papel crucial na comunicação dos resultados de forma clara e compreensível. Gráficos, *dashboards* interativos e técnicas de visualização de dados são utilizados para apresentar informações complexas de maneira acionável, facilitando o entendimento e o engajamento dos usuários (Davenport & Patil, 2012).

O termo "inteligência" começou a ser utilizado por pesquisadores em inteligência artificial na década de 1950. Já "inteligência de negócios" só se popularizou nas áreas de negócios e tecnologia da informação nos anos 1990 (Chen 2012). No final dos anos 2000, o conceito de "análise de negócios" foi introduzido para destacar o componente analítico essencial da inteligência de negócios (Davenport 2006). Mais recentemente, os termos "big data" e "análise de big data" passaram a ser empregados para descrever conjuntos de dados e técnicas analíticas em aplicações tão volumosas (variando de terabytes a exabytes) e complexas (de dados de sensores a mídias sociais) que demandam métodos avançados e específicos de análise.

Davenport e Chen exploram o processo evolutivo do Data Analytics em três etapas principais. Na primeira etapa de *analytics*, chamada por Davenport como a era do *business intelligence* e por Chen de BI&A 1.0, temos os principais pontos de comparação:

Tabela 1

Comparação entre Davenport e Chen sobre a primeira era do Data analytics

Aspectos	Davenport	Chen
Definição de BI (<i>Business Intelligence</i>)	Enfatiza a utilização de dados para uma compreensão profunda dos fenômenos de negócios, com foco na eficiência operacional.	Descreve BI como uma abordagem centrada em dados, com forte dependência de tecnologias de coleta e análise.

Tecnologias Utilizadas	Uso de <i>data warehouse</i> e software de BI para consultas e relatórios.	Uso de RDBMS e ferramentas ETL (extração, transformação e carga)
Fases de Desenvolvimento	Fase inicial com foco em relatórios e relatórios retrospectivos, sem explicações ou previsões.	Fase de BI&A 1.0, com o uso de ferramentas como OLAP, relatórios, visualização interativa e modelagem preditiva.
Adoção de BI no Mercado	A adoção de BI foi vista como uma vantagem para aumentar a eficiência operacional, mas sem um foco claro em “competir com análises”.	A adoção de BI&A 1.0, com maior foco na análise de dados para gerar informações estratégicas para decisões de negócios.
Competências Requeridas	Competências requeridas em gerenciamento de dados, com ênfase na preparação de dados para análise.	Exigência de habilidades em gerenciamento de dados e integração por meio de ferramentas como ETL.
Velocidade e Complexidade	Análise lenta e meticulosa, frequentemente levando semanas ou meses para ser realizada.	Tecnologias mais avançadas permitem maior automação e velocidade na análise e processamento de dados.
Foco no Tipo de Análise	Foco em dados históricos e no passado, sem fornecer previsões.	Foco em análise preditiva, mineração de dados, e modelagem preditiva.

Fonte: Adaptado de Davenport (2012) e Chen (2012)

Na segunda etapa de *Analytics*, chamada por Davenport (2012) como a era da big data e por Chen (2012) de BI&A 2.0, temos os principais pontos de comparação:

Tabela 2

Comparação entre Davenport (2012) e Chen (2012) sobre a segunda era do Data analytics

Aspectos	Davenport	Chen
Período e Início da Mudança	A fase <i>Analytics</i> 1.0 predominou até os anos 2000, com a chegada da big data.	Início do uso de dados e análises por empresas da Web 1.0, com o avanço para o Web 2.0.
Mudança no Tipo de Dados	O <i>big data</i> começou a ser caracterizado como diferente do <i>small data</i> , pois também era gerado externamente, não apenas por sistemas internos.	A coleta de dados não era mais apenas interna, mas também proveniente da web e dados públicos, com grande foco na coleta de dados gerados por usuários.
Tecnologias Utilizadas	Hadoop, NoSQL, e ferramentas de análise de dados não estruturados foram introduzidas.	Uso de tecnologias <i>Web</i> 2.0 como mineração de texto, <i>web mining</i> e análise de redes sociais, além de ferramentas como Google Analytics.

Análise e Velocidade	A análise de dados era mais lenta e focada em relatórios e modelos preditivos.	A análise foi mais dinâmica e focada em grandes volumes de dados gerados por interações online em tempo real.
Integração de Novas Tecnologias	Desenvolvimento e uso de ferramentas específicas para processar big data, como Hadoop e NoSQL.	Integração de novas técnicas de análise como mineração de texto e análise de redes sociais, além de foco em dados gerados por usuários em plataformas Web 2.0.
Enfoque no Tipo de Dados	Foco em dados estruturados e históricos.	Foco em dados não estruturados, como registros de navegação e interações de usuários na web.
Interatividade e Feedback	Pouca interatividade com o usuário; foco no processamento de dados e em decisões baseadas no passado.	Grande foco em interações em tempo real com os usuários, coletando <i>feedback</i> instantâneo das mídias sociais e outros canais interativos.
Análise Social	Menor foco em redes sociais.	Grande ênfase na análise de redes sociais e comportamento de consumidores em plataformas digitais.
Aplicações e Exemplos	Exemplo de LinkedIn, que desenvolveu produtos de dados baseados em interações sociais e de rede.	Foco nas ferramentas de análise web, como Google Analytics, para entender padrões de comportamento e compras online.

Fonte: Adaptado de Davenport (2012) e Chen (2012)

Na terceira etapa de analytics temos os seguintes pontos de comparação:

Tabela 3

Comparação entre Davenport (2012) e Chen (2012) sobre a terceira era do Data analytics

Aspecto	Davenport	Chen
Contexto de surgimento	A análise 3.0 surge após a adoção de grandes empresas de big data no Vale do Silício, com foco em produtos.	A pesquisa sobre o BI&A 3.0 está emergindo com a ascensão de dispositivos móveis e a "Internet das Coisas".
Tecnologias envolvidas	Uso de grandes volumes de dados para algoritmos de busca, recomendações e anúncios segmentados.	Foco em dispositivos móveis, sensores, RFID, códigos de barras e técnicas de análise de localização/contexto.

Desafios e Oportunidades	Desafios em como outras empresas podem seguir o exemplo e integrar análises nos processos de decisão.	Desafios de integrar e analisar dados de dispositivos móveis e de sensores, além do design de interfaces móveis.
Aplicações e Exemplos	Exemplo de empresas como LinkedIn, que usam dados para criar produtos como recomendações de pessoas e trabalho.	Aumento do uso de dispositivos móveis e Internet das Coisas para coletar e analisar dados em diversos setores.
Previsão futura	A análise 3.0 se disseminará para outras empresas fora da área de dados e tecnologia.	BI&A 3.0 ainda estará em estágio embrionário, com desafios técnicos e sem plataformas comerciais amplamente disponíveis.
Impacto no mercado	A era do <i>Analytics 3.0</i> não se limita a empresas de dados, mas se expande para qualquer empresa que lida com dados de consumidores.	O BI móvel está sendo considerado uma área disruptiva para o mercado, com grande potencial de transformação.

Fonte: Adaptado de Davenport (2012) e Chen (2012)

2.1.1 Dados estruturados e dados não estruturados

No contexto do *Data Analytics*, os dados podem ser classificados em dois principais tipos: estruturados e não estruturados. Os dados estruturados são aqueles que possuem um formato predefinido e organizado em uma estrutura bem definida, geralmente seguindo um esquema de tabela. Esses dados são altamente organizados, com campos, colunas e relações estabelecidas. Um exemplo comum de dados estruturados é uma tabela em um banco de dados relacional (Abiteboul, Mangalam, & Vianu, 1995).

Os dados não estruturados são aqueles que não seguem uma estrutura predefinida e não são facilmente organizados em formatos tabulares. Eles podem ser em formato de texto livre, áudio, vídeo, imagens, redes sociais, entre outros. Os dados não estruturados representam uma grande parte do volume total de dados gerados atualmente, e sua análise apresenta desafios adicionais devido à falta de estrutura e à necessidade de técnicas avançadas de processamento e análise (Kelleher, 2020).

O processamento e a análise de dados estruturados são relativamente mais simples devido à sua natureza organizada, o que permite o uso de técnicas tradicionais de bancos de dados relacionais (Kelleher, 2020). No entanto, os dados não estruturados exigem abordagens mais avançadas, como processamento de linguagem natural, aprendizado de máquina e técnicas de mineração de dados, para extrair informações e conhecimentos valiosos (Alpaydin, 2020).

De acordo com os estudos de Han, Kamber e Pei (2011), o processamento de dados não estruturados requer o uso de técnicas de mineração de texto e análise de sentimento para extrair informações relevantes. Além disso, a aplicação de técnicas de aprendizado de máquina, como algoritmos de classificação e agrupamento, é fundamental para organizar e interpretar os dados não estruturados (Hastie, Tibshirani e Friedman, 2017).

A evolução das tecnologias de *Data Analytics* e a disponibilidade de ferramentas específicas permitem o processamento e a análise eficientes tanto de dados estruturados quanto de dados não estruturados. O uso de plataformas como o Hadoop e o Apache Spark, conforme mencionado por

Zaharia, (2016), possibilita a manipulação e o processamento escaláveis de grandes volumes de dados não estruturados.

2.2 Ferramentas de Data Analytics

As ferramentas e tecnologias de *Data Analytics* desempenham um papel crucial no processamento, análise e gerenciamento eficiente de grandes volumes de dados. Algumas das principais ferramentas e tecnologias utilizadas no contexto do *Data Analytics* são descritas na Tabela 4.

Tabela 4

Ferramentas de Data Analytics

Ferramenta	Descrição
Apache Hadoop	Plataforma de código aberto amplamente utilizada para processamento e armazenamento distribuído de grandes volumes de dados. Vavilapalli (2013) descreve a arquitetura e os componentes do Hadoop, incluindo o Hadoop Distributed File System (HDFS) e o <i>framework</i> de processamento MapReduce.
SQL (<i>Structured Query Language</i>)	Linguagem amplamente utilizada para consultas e manipulação de dados em bancos de dados relacionais. Codd (1970) introduziu os princípios do modelo relacional e definiu as bases da linguagem SQL, que se tornou uma linguagem padrão no gerenciamento de bancos de dados relacionais.
MongoDB	Banco de dados NoSQL orientado a documentos, projetado para armazenar e recuperar dados de forma eficiente. Chodorow e Dirolf (2010) apresentam as características e a arquitetura do MongoDB, enfatizando sua escalabilidade horizontal e flexibilidade no modelo de dados.
DataBricks	Serviço de análise baseado no projeto de código aberto Apache Spark. O Apache Spark é um ambiente de processamento em lote e em tempo real. Sua popularidade entre cientistas de dados se deve à capacidade de lidar com grandes volumes de dados, além de suportar processamento de <i>streaming</i> , computação em grafos, aprendizado de máquina e consultas interativas (Etaati, 2019).
Power BI	Suíte de ferramentas de análise de negócios da Microsoft, que permite visualização interativa de dados e criação de painéis de controle. Usmani (2018) descreve os recursos do Power BI, como a criação de relatórios interativos e o uso de recursos avançados, como a análise preditiva.

2.3 Categorias de mineração de dados e de aprendizado de máquina

As técnicas de mineração de dados podem ser divididas em três categorias principais: descritiva e preditiva e prescritiva, cada uma com sua aplicação distinta na análise de grandes volumes de dados (Mohini Divivedi e Rajiva 2019). As técnicas descritivas de mineração de dados têm como principal objetivo explorar e resumir dados históricos, permitindo que os analistas entendam melhor os padrões e comportamentos dos dados (Bello, 2024).

A análise descritiva tem como propósito descrever um conjunto de dados. Ela visa resumir e apresentar informações de forma clara e concisa, facilitando a compreensão dos fenômenos investigados. Por meio de medidas de tendência central (como média, mediana e moda) e de dispersão (como desvio padrão e variância), é possível caracterizar as principais características dos dados (Kuhn, 2015).

A análise preditiva vai além da mera descrição dos dados, buscando prever eventos futuros com base em informações históricas. Utilizando técnicas estatísticas e algoritmos de aprendizado de máquina, é possível desenvolver modelos que identificam padrões e tendências, permitindo previsões mais precisas (Hair et al., 2010).

A análise prescritiva representa o nível mais avançado da análise de dados, pois não se limita a descrever o passado ou prever o futuro, mas também recomenda ações para otimizar resultados. Por meio de técnicas de otimização e simulação, é possível identificar as melhores opções para alcançar objetivos específicos (Kuhn, 2015).

A tabela 5 resume os tipos de análise, qual o objetivo principal, quais técnicas utilizadas e qual o foco de cada conjunto de técnicas.

Tabela 5

Objetivos, técnicas e foco por tipo de análise

Tipo de Análise	Objetivo Principal	Técnicas Utilizadas	Foco
Descritiva	Descrever e sumarizar dados	Medidas de tendência central (média, mediana, moda), medidas de dispersão (desvio padrão, variância)	Caracterizar os dados
Preditiva	Prever eventos futuros	Estatística, aprendizado de máquina, modelos preditivos	Identificar padrões e tendências
Prescritiva	Recomendar ações para otimização	Otimização, simulação	Tomar decisões estratégicas

Fonte: Adaptado de Kuhn (2015) e Hair (2010)

Uma das abordagens mais comuns dentro dessa categoria é a análise de *clusters*, que agrupa dados semelhantes em categorias, permitindo que os gestores identifiquem segmentos ou grupos específicos dentro de um conjunto de dados. Isso é especialmente útil em setores como o bancário e o de seguros, onde as empresas podem querer segmentar seus clientes para oferecer produtos ou serviços personalizados (Roshan, Nashra & Fahad, 2016).

A análise de regras de associação, que busca encontrar relações entre diferentes variáveis, é uma técnica amplamente aplicada no marketing e em setores de consumo para entender como diferentes características dos clientes estão inter-relacionadas (Huang, Qiu, Yang & Tian 2010). Outro método amplamente utilizado em técnicas de mineração preditiva é a regressão, que permite modelar a relação entre uma variável dependente e uma ou mais variáveis independentes, possibilitando previsões precisas para diversos contextos financeiros (Ganesh, Kesavulu & Reddy, 2022). Adicionalmente, o uso de redes neurais e algoritmos de aprendizado de máquina (*machine learning*) tem se tornado cada vez mais comum na mineração de dados preditiva, dada a sua capacidade de identificar padrões complexos e não lineares nos dados (Almeida e Passari, 2023).

2.3.1 *Aprendizado de máquina*

O aprendizado de máquina desempenha um papel crucial na análise de dados em *Data Analytics*. Duas abordagens amplamente utilizadas são o aprendizado supervisionado e o aprendizado não supervisionado. O aprendizado supervisionado envolve o treinamento de um modelo com base em pares de dados de entrada e saída conhecidos, permitindo que o modelo faça previsões ou classificações em novos conjuntos de dados. Um exemplo comum é o algoritmo de regressão linear, utilizado para prever valores numéricos com base em variáveis de entrada (Bishop, 2006; Hastie et al., 2017).

No aprendizado não supervisionado, não há informações prévias sobre as saídas esperadas. O objetivo é encontrar padrões, estruturas ou agrupamentos nos dados sem a necessidade de rótulos pré-existentes. Uma técnica comum é o algoritmo de clusterização, que agrupa os dados com base em sua similaridade. O trabalho de Tan (2018) explora os fundamentos e aplicações do aprendizado não supervisionado.

Em muitos casos, é vantajoso combinar abordagens supervisionadas e não supervisionadas para obter melhores resultados. Por exemplo, o aprendizado semi-supervisionado utiliza um conjunto limitado de dados rotulados em conjunto com um grande conjunto de dados não rotulados, permitindo que o modelo aprenda com os dados rotulados e generalize para os dados não rotulados (Zhu, 2009).

2.3.1.1. Algoritmos de classificação

Os algoritmos de classificação são métodos de aprendizado de máquina frequentemente empregados em Análise de Dados para agrupar dados em categorias ou classes pré-estabelecidas. Esses algoritmos são fundamentais em várias aplicações, como análise financeira, identificação de fraudes, segmentação de clientes e previsão de risco de crédito (Avelar et al., 2025). Na administração financeira, os algoritmos ajudam na interpretação de grandes volumes de dados, permitindo decisões mais fundamentadas e precisas (Satler, 2024).

A aplicação de algoritmos de classificação no contexto da administração financeira ilustra como o *Data Analytics* pode aprimorar a exatidão das análises e a rapidez das decisões. Conforme destacado por Suryanarayana e Kumar (2023), esses algoritmos, incluindo árvores de decisão, *k-nearest neighbors* e *naive Bayes*, têm se mostrado eficazes na previsão de variáveis econômico-financeiras. Além disso, a inteligência artificial (IA) tem se tornado uma ferramenta crucial na gestão financeira, contribuindo para a automação de processos e a otimização da análise de dados (Satler, 2024). Embora a implementação desses algoritmos ofereça inúmeras vantagens, também levanta questões éticas e técnicas que devem ser consideradas.

A dependência de dados históricos pode gerar vieses nas análises e a complexidade dos algoritmos pode dificultar a transparência nas decisões financeiras (Avelar et al., 2025). Portanto, é essencial que a implementação da IA na administração financeira seja acompanhada por boas práticas de governança e supervisão humana para maximizar seus benefícios.

2.3.1.2. Algoritmos de Associação ou Clustering

Os algoritmos de agrupamento e associação são instrumentos eficazes na mineração de dados, utilizados para identificar padrões ocultos em grandes volumes de informações. Ambos desempenham um papel crucial na análise de dados, embora com metas e métodos diferentes (Vashi, 2023). Os algoritmos de associação têm como objetivo identificar regras que explicam a relação entre itens em um conjunto de dados; em outras palavras, eles buscam descobrir quais itens costumam aparecer juntos com frequência (Nazareth & Reddy, 2023).

Por outro lado, o *clustering* é uma técnica de aprendizado não supervisionado que combina dados em agrupamentos, ou seja, conjuntos de objetos com características semelhantes. O conceito fundamental é que os elementos dentro de um mesmo agrupamento sejam mais parecidos entre si do que os elementos de agrupamentos distintos (Gupta & Pravin, 2020). Essa técnica é amplamente aplicada na segmentação de mercado e na análise de comportamento do consumidor, permitindo que empresas entendam melhor as relações entre diferentes grupos (Liu et al., 2021).

A mineração de regras de associação é frequentemente exemplificada através do conceito de cesta de compras, onde se analisa quais produtos são comprados juntos. Essa abordagem permite que varejistas otimizem suas estratégias de marketing e recomendação (AWS, 2022). Já o agrupamento pode ser utilizado para identificar segmentos de clientes com comportamentos similares, facilitando a personalização dos serviços oferecidos (Microsoft Learn, 2023).

2.3.1.3. Regressão logística binária

A regressão logística binária tem como objetivo principal estimar a probabilidade de ocorrência de um evento definido por uma variável dependente Y , que assume uma forma qualitativa dicotômica, onde $Y = 1$ representa a ocorrência do evento de interesse e $Y = 0$ indica a ausência do evento. Essa estimativa é realizada com base no comportamento de um conjunto de variáveis explicativas, permitindo prever a ocorrência do evento a partir de suas influências (Fávero e Belfiore, 2017).

Modelos de regressão logística binária são amplamente utilizados para estimar a probabilidade de inadimplência (Daros & Pinto, 2017). Assim, modelos de regressão binária por meio das funções logit e probit são muito trabalhados visto que exploram a questão dual de o indivíduo estar ou não inadimplente ou possuir ou não um aspecto que o afete.

2.3.1.4. Séries Temporais

Séries temporais são conjuntos de dados organizados em ordem cronológica, onde cada ponto de dados é registrado em intervalos de tempo específicos. Sua principal característica é que o tempo exerça um papel fundamental no comportamento dos dados. A análise de séries temporais pode incluir a identificação de tendências (mudanças de longo prazo), sazonalidade (padrões repetitivos ao longo de ciclos temporais, como estações do ano) e componentes aleatórios. Métodos como decomposição de séries temporais, análise de autocorrelação e modelos ARIMA são usados para prever comportamentos baseados em dados históricos.

De acordo com Ballou (2005), as previsões de demanda são utilizadas como subsídios às decisões empresariais, visando planejar desde o nível de produção até a distribuição, estocagem, fluxo de caixa e contratação de pessoal. A utilização de séries temporais na predição de demanda de caixa, de acordo com Zanella, Barrichello e Rodrigues (2016), é essencial, pois a previsão da demanda é a base para o planejamento estratégico da produção, vendas e finanças de qualquer empresa. Com isso, as empresas podem desenvolver planos de capacidade, fluxo de caixa e vendas.

No contexto financeiro, a análise de séries temporais é especialmente útil para prever preços de ações, taxas de câmbio e risco de crédito. A capacidade de identificar padrões sazonais ou tendências pode auxiliar na mitigação de riscos e na tomada de decisões estratégicas (Hyndman & Athanasopoulos, 2021).

2.3.1.5 Regressão Linear Múltipla

Segundo Fávero e Belfiore (2009), a técnica de regressão linear oferece, prioritariamente, a possibilidade de que seja estudada a relação entre uma ou mais variáveis explicativas, que se apresentam na forma linear, e uma variável dependente quantitativa.

Sobre a aplicação das técnicas de regressão como instrumento de análise e previsão de custos na gestão, Sell (2005) argumenta que essas técnicas podem ser empregadas para estimar o valor de uma variável com base em outra variável já conhecida, explicar o comportamento dos custos previstos em relação aos realizados e, ainda, prever custos futuros. Dessa forma, será utilizado a regressão linear múltipla para a previsão de despesas operacionais.

2.3.1.6 Máquinas de Vetores de Suporte - SVM

Em linha com a obra *Machine Learning* de Mitchell (1997), as Máquinas de Vetores de Suporte (SVMs, do inglês *Support Vector Machines*) constituem uma técnica de aprendizado que vem recebendo crescente atenção da comunidade. O SVM é uma técnica de aprendizado de máquina desenvolvida por Vapnik (1995), fundamentada na Teoria de Aprendizado Estatístico e utilizada para a classificação de dados (Lorena & Carvalho, 2003).

A gestão de estoques consiste em um conjunto de atividades voltadas a assegurar um fluxo contínuo e equilibrado tanto na produção quanto nas vendas da organização, contribuindo para a eficiência operacional (Lucena, 2019). O método SVM pode ser aplicado para examinar um conjunto de dados com características de produtos, como preço, qualidade, marca e outros

aspectos. Com base nesses dados, o SVM desenvolve um modelo matemático que classifica os produtos em diferentes categorias (Feurer, 2019).

2.3.1.7 Análise de Cluster - K – Means

A análise de cluster diz respeito de agrupamentos que representa um conjunto de técnicas exploratórias muito úteis e que podem ser aplicadas quando há a intenção de se verificar a existência de comportamentos semelhantes entre observações. Com o objetivo de e criarem grupos, ou clusters, em que prevaleça a homogeneidade interna.

De acordo com Fávero e Belfiore (2009), esse conjunto de técnicas, também conhecido por análise de conglomerados ou análise de clusters, tem por objetivo principal a alocação de observações em uma quantidade relativamente pequena de agrupamentos homogêneos internamente e heterogêneos entre si e que representem o comportamento conjunto das observações a partir de determinadas variáveis.

2.4 Gestão financeira

A gestão financeira é um dos pilares fundamentais para o sucesso de qualquer organização, sendo definida como o conjunto de práticas, processos e ações voltados ao planejamento, análise e controle das atividades financeiras de uma empresa (Voitto, 2024). Esse conceito abrange desde a administração eficiente dos recursos financeiros disponíveis até a formulação de estratégias que garantam a sustentabilidade do negócio e maximizem os lucros. Além disso, a gestão financeira desempenha um papel estratégico ao permitir que as empresas tomem decisões informadas sobre investimentos, captação de recursos e alocação de capital (Sebrae, 2023).

Segundo Gitman (2018), a gestão financeira também é essencial para alinhar as operações diárias aos objetivos de longo prazo da organização. A importância da gestão financeira vai além do simples controle de custos ou aumento da lucratividade. Ela é fundamental para garantir a sobrevivência das empresas em um ambiente de negócios cada vez mais competitivo e dinâmico. De acordo com Gibson (2019), a gestão financeira eficaz permite que as organizações se adaptem rapidamente às mudanças nas condições econômicas e aproveitem oportunidades estratégicas que surgem no mercado. Além disso, ela é essencial para construir confiança entre investidores, credores e outros stakeholders.

2.4.1. O planejamento financeiro

O planejamento financeiro é considerado a base para uma gestão financeira eficaz. Ele consiste na definição de metas financeiras, projeção de receitas e despesas futuras, bem como na elaboração de orçamentos detalhados que orientem as operações da empresa (Viana de Souza, de Macedo Farias, Backes Steppan & da Silva, 2011). Essa prática permite que as organizações antecipem necessidades futuras e se preparem para imprevistos. Segundo Gitman (2018), o planejamento financeiro não apenas orienta as operações diárias, mas também estabelece uma visão estratégica de longo prazo. Além disso, o planejamento financeiro é essencial para a sobrevivência das empresas em ambientes econômicos voláteis. Ele possibilita a criação de cenários alternativos que ajudam os gestores a se adaptarem rapidamente às mudanças no mercado ou às flutuações econômicas (FIA, 2024). Gitman (2018) destaca que essa prática deve ser revisada regularmente para refletir as condições atuais do mercado e alinhar-se aos objetivos organizacionais.

O planejamento financeiro também desempenha um papel crucial na definição das prioridades organizacionais. Por meio dele, os gestores podem decidir quais projetos devem receber mais recursos e quais precisam ser adiados ou ajustados. Segundo Gibson (2019), essa priorização é fundamental para garantir que os recursos financeiros sejam alocados de forma eficiente e estratégica. Além disso, o planejamento financeiro ajuda a identificar possíveis lacunas no fluxo de caixa e permite que as empresas busquem fontes alternativas de financiamento antes que problemas financeiros se tornem críticos (Brigham, 2016).

Outro aspecto relevante do planejamento financeiro é sua relação com o controle orçamentário. O orçamento é uma ferramenta indispensável para monitorar o desempenho financeiro da empresa em relação às metas estabelecidas. De acordo com Brigham (2016), um orçamento bem elaborado serve como um guia para todas as áreas da organização, garantindo que os recursos sejam utilizados de maneira eficiente. Além disso, ele permite identificar desvios em relação ao plano original e implementar ações corretivas quando necessário.

2.4.2. A análise financeira

A análise financeira é uma ferramenta indispensável para avaliar a saúde econômica e financeira de uma organização. Ela envolve o exame detalhado das demonstrações financeiras, como balanço patrimonial e demonstração de resultados, para identificar pontos fortes e fracos na estrutura financeira da empresa (Gibson, 2019). Essas análises permitem aos gestores tomar decisões mais informadas e estratégicas.

Entre as técnicas mais utilizadas na análise financeira estão os índices financeiros. Indicadores como liquidez corrente, margem de lucro e retorno sobre o investimento são amplamente empregados para medir diferentes aspectos do desempenho financeiro (Gitman, 2018). Esses índices não apenas auxiliam na avaliação interna da empresa, mas também são ferramentas importantes para investidores e credores avaliarem o risco associado à organização. Além disso, a análise financeira deve ser um processo contínuo. Revisões regulares ajudam a identificar tendências emergentes e ajustar estratégias conforme necessário (Gibson, 2019). Essa prática é particularmente importante em setores altamente competitivos ou em rápida mudança.

A análise horizontal e vertical das demonstrações financeiras também é amplamente utilizada como parte desse processo. Essas análises permitem comparar os resultados financeiros ao longo do tempo ou em relação a benchmarks do setor (Gibson, 2019). Segundo Altman (2017), essas técnicas são cruciais para identificar variações significativas nos números financeiros que podem indicar problemas ou oportunidades.

2.4.3. A gestão do capital de giro

A gestão do capital de giro refere-se à administração eficiente dos ativos circulantes e passivos circulantes visando garantir liquidez suficiente para atender às obrigações operacionais diárias da empresa sem comprometer seu crescimento futuro (Brigham, 2012). Uma boa gestão do capital de giro é crucial pois impacta diretamente na capacidade da empresa operar eficientemente sem enfrentar problemas financeiros. Uma das principais componentes do capital de giro inclui contas a receber estoques contas pagar entre outros fatores relevantes. A otimização desses elementos pode levar à melhoria significativa no fluxo caixa permitindo assim maior flexibilidade nas operações financeiras gerais da organização (Gibson, 2019). Por exemplo implementar políticas eficazes cobrança pode reduzir significativamente o tempo necessário receber pagamentos aumentando assim liquidez disponível para reinvestimentos ou pagamento dívidas existentes (Hopkin, 2017).

Da mesma forma, manter níveis adequados de estoque é importante, pois evita excessos e, conseqüentemente, reduz os custos de armazenamento, ao mesmo tempo em que assegura a capacidade de atender prontamente à demanda dos clientes. Além disso monitorar continuamente indicadores relacionados à eficiência operacional pode ajudar identificar áreas onde melhorias podem ser feitas resultando em economias adicionais aumentando margem lucro geral da empresa (Saunders & Cornett, 2018).

2.4.4. A gestão do risco financeiro

A gestão de risco financeiro é outro componente essencial da gestão financeira. Ela envolve a identificação, avaliação e mitigação dos riscos financeiros que podem afetar negativamente os ativos da empresa (Hopkin, 2017). Esses riscos incluem flutuações cambiais, variações nas taxas de juros e inadimplência por parte dos clientes. De acordo com Hopkin (2017), uma abordagem eficaz

à gestão de risco começa com a identificação dos riscos mais críticos para a organização. Isso pode incluir tanto fatores internos quanto externos. Após essa identificação inicial, os riscos devem ser avaliados em termos de probabilidade e impacto potencial. Essa avaliação permite priorizar os riscos que exigem atenção imediata. Gitman (2018) destaca que estratégias como diversificação dos investimentos e uso de instrumentos financeiros derivativos podem ser eficazes na mitigação dos riscos financeiros.

Um ponto importante a ser salientado é o relativo à governança corporativa, a qual se refere ao sistema pelo qual as empresas são dirigidas controladas e administradas incluindo práticas relacionadas à transparência responsabilidade social ética entre outros aspectos importantes (Saunders & Cornett, 2018). Empresas com práticas robustas em governança corporativa tendem a apresentar melhor desempenho financeiro pois são capazes não apenas minimizar riscos, mas também maximizar oportunidades através da implementação eficaz das estratégias financeiras adequadas (Hopkin, 2017).

Além disso, essas práticas ajudam na construção da confiança com investidores clientes fornecedores entre outros stakeholders essenciais ao sucesso organizacional. Um aspecto crítico da governança corporativa é o papel do conselho administrativo na supervisão das atividades financeiras da empresa. Conselhos bem estruturados podem fornecer orientação estratégica valiosa além de garantir que haja controles adequados sobre as operações financeiras (Saunders & Cornett, 2018).

O gerenciamento de risco de crédito é fundamental para a estabilidade financeira global. Lassance et al. (2021) definem esse gerenciamento como a administração e controle da inadimplência em obrigações financeiras. Se mal gerida, ela pode causar perdas significativas não só para uma única instituição, mas também desencadear crises financeiras sistêmicas em escala global em caso de eventos de inadimplência generalizada. Isso reforça a necessidade de abordagens analíticas robustas para mitigar os riscos.

Além disso, Scott et al. (2024) apontam que a complexidade crescente do sistema financeiro e a alta volatilidade econômica impõem desafios adicionais, exigindo metodologias mais sofisticadas para a análise de crédito. As abordagens tradicionais, limitadas a variáveis financeiras e premissas lineares, são insuficientes diante da grande diversidade e volume de dados disponíveis atualmente (Dewasiri et al., 2024).

2.5 O uso da tecnologia nas áreas de contabilidade e finanças

A transformação digital tem revolucionado diversos setores ao integrar tecnologias como inteligência artificial, *analytics* e computação em nuvem, proporcionando melhorias significativas na experiência do cliente e na eficiência operacional (Saunders & Cornett, 2018). A capacidade de coletar e processar dados em tempo real permite que os gestores tenham acesso a informações atualizadas e possam tomar decisões mais embasadas e ágeis.

A tecnologia tem transformado significativamente a forma como as empresas gerenciam suas finanças. Ferramentas digitais permitem análises mais rápidas e precisas das operações financeiras enquanto automatizam processos manuais demorados (Voitto, 2024). Por exemplo sistemas baseados em inteligência artificial podem prever tendências econômicas futuras ajudando gestores tomar decisões mais informadas.

O uso dessa tecnologia pode ajudar as empresas a reduzir fraudes, bem como melhorar a rastreabilidade das transações e, além disso, facilitar auditorias mais eficientes. Ademais, outra área em que a tecnologia tem apresentado avanços significativos é a análise preditiva. Por meio de algoritmos sofisticados, as empresas conseguem analisar grandes volumes de dados históricos e, assim, identificar padrões comportamentais, bem como prever resultados futuros com maior precisão (Voitto, 2024). Dessa forma, essa capacidade analítica possibilita que as organizações tomem decisões proativas, em vez de reativas, o que, por conseguinte, contribui para o fortalecimento de sua posição competitiva no mercado.

As fintechs têm desempenhado um papel crucial nessa transformação digital no setor financeiro. Essas empresas utilizam tecnologia avançada para oferecer serviços financeiros inovadores que desafiam modelos tradicionais (Pagar.me, 2024). Através da automação de processos, como a concessão de crédito e da análise de risco, tornaram-se mais eficientes, reduzindo custos operacionais enquanto melhoram a experiência do cliente. Além disso, tecnologias emergentes como *blockchain* estão começando a impactar significativamente o setor financeiro, oferecendo maior transparência e segurança em transações financeiras complexas (Gitman, 2018).

2.5.1 A utilização de ferramentas de Data Analytics na Contabilidade

A contribuição para a área de Contabilidade é significativa, especialmente com a aplicação de ferramentas de *Data Analytics*. A contabilidade moderna não se limita apenas ao registro de transações financeiras, mas também envolve a análise de dados para fornecer informações que podem orientar a tomada de decisões estratégicas (Cruz & Oliveira, 2023). Com a experiência e conhecimento em *Data Analytics*, tem o poder de transformar a maneira como os dados contábeis são coletados, analisados e utilizados.

A implementação de ferramentas de *Data Analytics* pode melhorar a precisão e a eficiência dos processos contábeis. Isso inclui a automação de tarefas repetitivas, como a reconciliação de contas, a detecção de fraudes e a análise de tendências financeiras (Mhlanga, 2024). Além disso, a capacidade de analisar grandes volumes de dados em tempo real permite que os contadores identifiquem rapidamente quaisquer discrepâncias ou anomalias, garantindo a integridade dos registros financeiros.

O uso de *Data Analytics* pode ajudar a contabilidade a se tornar mais proativa em vez de reativa. Em vez de apenas registrar transações passadas, os contadores podem usar análises preditivas para antecipar tendências futuras e tomar medidas preventivas (Araújo, Behr & Schiavi, 2023). Isso pode incluir a previsão de fluxos de caixa, a identificação de possíveis problemas de liquidez e a recomendação de estratégias para mitigar riscos financeiros. Outro aspecto importante é a capacidade de prever tendências e riscos econômicos. Ferramentas como *machine learning* permitem que as instituições financeiras criem modelos preditivos capazes de antecipar tendências do mercado e riscos econômicos, facilitando estratégias de mitigação de riscos e otimizando a alocação de recursos financeiros (Mhlanga, 2024).

2.5.2 A utilização de ferramentas de Data Analytics na Gestão Financeira

O tema do *Data Analytics* na gestão financeira tem sido amplamente estudado e discutido em diversas publicações acadêmicas e especializadas. *Data Analytics* refere-se ao processo de examinar grandes conjuntos de dados para extrair informações úteis que auxiliam na tomada de decisões informadas, sendo uma prática essencial para o gerenciamento eficiente das finanças corporativas (Gupta & Mehta, 2021). Essas ferramentas permitem uma análise mais precisa e detalhada dos dados financeiros, facilitando a identificação de tendências, padrões de comportamento e oportunidades de melhoria (Araújo et al., 2023). Ainda, conforme os autores, a adoção de ferramentas de *Business Analytics (BA)* na contabilidade e na gestão financeira não apenas melhora a eficiência operacional, mas também proporciona revelações sobre conjuntos de dados, que podem ser utilizados para prever eventos futuros e otimizar processos financeiros. Além disso, a incorporação de *Data Analytics* auxilia na elaboração de estratégias de longo prazo (Gartner, 2023).

Com o aumento da complexidade dos dados financeiros e a necessidade de respostas rápidas, as ferramentas analíticas têm se tornado indispensáveis (Hasan, Hoque, & Le, 2023). A utilização dessas ferramentas pode trazer diversos ganhos significativos para as empresas, incluindo a capacidade de coletar e processar dados em tempo real, prever tendências e riscos econômicos, além da identificação eficaz de fraudes financeiras (Santos & Oliveira, 2021).

Uma das aplicações mais significativas do *Data Analytics* na gestão financeira é a detecção de fraudes financeiras. De acordo com Gupta e Mehta (2021), técnicas como mineração de dados têm se mostrado eficazes na identificação de fraudes em demonstrações financeiras. A literatura

aponta que a classificação é uma técnica amplamente utilizada para detectar fraudes financeiras. Essa abordagem envolve a criação de modelos que podem classificar transações como fraudulentas ou não fraudulentas com base em características específicas (Azevedo & Figueira, 2020). Os métodos mais comuns incluem regressão logística, redes neurais artificiais (ANN) e máquinas de suporte vetorial (Han et al., 2011). Um estudo realizado por Azevedo & Figueira, (2020) demonstrou que a aplicação dessas técnicas pode aumentar significativamente a precisão na identificação de fraudes.

Além da detecção de fraudes, o *Data Analytics* também desempenha um papel crucial na otimização do desempenho financeiro das organizações. As ferramentas analíticas permitem que os gestores identifiquem áreas que necessitam de melhorias e implementem estratégias baseadas em dados concretos. Por exemplo, a análise do fluxo de caixa pode revelar padrões nos recebimentos e pagamentos que ajudam as empresas a gerenciar melhor sua liquidez (Gaboardi & Ferreira, 2020).

A capacidade de prever tendências financeiras é outra vantagem significativa do uso do *Data Analytics*. Com técnicas preditivas, as empresas podem antecipar variações no mercado e ajustar suas estratégias financeiras em conformidade. Isso é particularmente importante em setores voláteis onde mudanças rápidas podem afetar drasticamente os resultados financeiros (Cruz & Oliveira, 2023). O autor utilizou um modelo estatístico para analisar uma amostra significativa de empresas e concluiu que os indicadores financeiros poderiam prever com precisão a probabilidade de insolvência antes que ela ocorresse.

As ferramentas de *Data Analytics* também melhoram a tomada de decisão dentro das organizações financeiras. Com acesso a análises detalhadas e relatórios gerados por meio dessas ferramentas, os gestores podem tomar decisões mais informadas sobre investimentos, cortes orçamentários e alocação de recursos (Gray & Debreceeny, 2014). A capacidade de visualizar dados complexos através de dashboards interativos facilita o entendimento das informações financeiras e permite uma resposta mais rápida às mudanças no ambiente econômico.

A utilização dessas ferramentas também promove uma cultura organizacional orientada por dados. À medida que as equipes financeiras começam a confiar nas análises baseadas em dados para guiar suas decisões, elas se tornam mais proativas em sua abordagem à gestão financeira (Zhou & Kapoor, 2011). Isso não apenas melhora o desempenho financeiro da organização, mas também aumenta sua resiliência em tempos desafiadores.

2.5.3. A utilização de Data Analytics no monitoramento do Desempenho Financeiro

A análise de desempenho financeiro é crucial para a saúde financeira de qualquer organização. Com o advento das tecnologias de Data Analytics, essa análise tornou-se ainda mais precisa e eficiente. Ferramentas como dashboards e relatórios automatizados oferecem uma visão em tempo real sobre a lucratividade, despesas e margens de lucro, ajudando os gestores a tomar decisões mais rápidas e informadas (Santos e Oliveira, 2021, Accenture, 2018). Além disso, a integração de algoritmos de aprendizado de máquina pode prever tendências financeiras futuras, proporcionando uma vantagem competitiva significativa (Canhoto & Clear, 2020).

Estudos indicam que a adoção de tais tecnologias pode aumentar a precisão das previsões financeiras em até 30% (Bank of America, 2019). Dessa forma, a análise de desempenho financeiro baseada em dados não apenas melhora a eficiência operacional, mas também contribui para a sustentabilidade a longo prazo das organizações (Bodjov, 2018).

2.5.4. A utilização de ferramentas de Data Analytics no Crédito e Cobrança

A análise preditiva, uma faceta do *Data Analytics*, é particularmente relevante, pois permite que os profissionais financeiros antecipem riscos e oportunidades, facilitando uma resposta rápida às dinâmicas do mercado (Ilumeo, 2024). Em instituições financeiras, por exemplo, modelos de aprendizado de máquina são usados para avaliar o perfil de risco dos clientes e prever a probabilidade de inadimplência, melhorando as decisões de crédito e as políticas de mitigação de

risco(Hopkin, 2017). Ferramentas de *Data Analytics* também são utilizadas para monitorar continuamente o comportamento dos clientes, ajustando as estratégias de crédito conforme necessário (ING, 2018). A implementação de tais tecnologias tem mostrado reduzir as taxas de inadimplência (Bodjov, 2018). Além disso, a análise preditiva permite que as instituições financeiras desenvolvam políticas de crédito mais robustas e personalizadas, aumentando a satisfação do cliente e a rentabilidade (Canhoto & Clear, 2020).

A gestão de risco e a análise de crédito são componentes essenciais para a estabilidade financeira de qualquer instituição. A análise de dados permite identificar e quantificar riscos financeiros de forma mais eficiente. Em instituições financeiras, por exemplo, modelos de aprendizado de máquina são usados para avaliar o perfil de risco dos clientes e prever a probabilidade de inadimplência, melhorando as decisões de crédito e as políticas de mitigação de risco (Chase, JP Morgan, 2017).

2.5.5. Desafios relativos à implementação das ferramentas de *Data Analytics*

A implementação dessas ferramentas também apresenta desafios. Um dos principais desafios é garantir a qualidade e a consistência dos dados. Dados imprecisos ou incompletos podem levar a análises errôneas e decisões inadequadas (Yamanishi et al., 2004). Portanto, é essencial que as empresas invistam em processos robustos de coleta, verificação e limpeza de dados (Cruz & Oliveira, 2023). Outro desafio é a necessidade de uma infraestrutura tecnológica adequada. A gestão de grandes volumes de dados requer sistemas de armazenamento e processamento escaláveis, além de recursos de hardware e software capazes de lidar com a complexidade dos dados financeiros. Sem uma infraestrutura adequada, a eficácia do uso de *Data Analytics* pode ser limitada.

Outro desafio é a resistência à mudança dentro das organizações. A aceitação e o uso dessas ferramentas ainda enfrentam desafios, como apontado em um estudo sobre a aceitação de *Big Data Analytics* por profissionais da área financeira (Oliveira, Santos & Decoster, 2022). Muitas vezes, os funcionários estão acostumados a métodos tradicionais e podem hesitar em adotar novas tecnologias ou processos baseados em dados. Para superar essa resistência, as empresas devem investir em treinamento e desenvolvimento contínuo para suas equipes financeiras (Kotsiantis et al., 2006).

Adicionalmente, é importante considerar questões éticas relacionadas ao uso do *Data Analytics*. A coleta e análise de dados financeiros devem ser realizadas com transparência e respeito à privacidade dos indivíduos envolvidos. As organizações devem estabelecer políticas claras sobre como os dados são coletados, armazenados e utilizados para garantir conformidade legal e ética (Rahman & Afroz, 2013). No entanto, os benefícios superam as dificuldades, pois a capacidade de transformar dados brutos em informações estratégicas é crucial para a competitividade das empresas no cenário atual.

2.6. Proposições de Pesquisa

A aplicação de ferramentas de *Data Analytics* na gestão do Crédito e Cobrança tem se mostrado fundamental para aprimorar a capacidade dos gestores financeiros em tomar decisões estratégicas. A análise de dados em tempo real permite identificar padrões de inadimplência, prever riscos de crédito e otimizar estratégias de cobrança, contribuindo para decisões mais embasadas (Chen et al., 2021).

Além disso, pesquisas recentes destacam que a análise preditiva e o machine learning podem melhorar significativamente a eficiência na gestão de crédito. Um estudo de Delen & Ram (2018) demonstra que modelos baseados em *Data Analytics* aumentam a precisão na avaliação de risco de crédito, reduzindo perdas financeiras. Já Kumar & Ravi (2020) evidenciam que a automação de processos de cobrança, aliada a análises de dados históricos, eleva a recuperação de ativos e aprimora a alocação de recursos.

De acordo com a pesquisa da McKinsey (2022), empresas que adotam *Data Analytics* avançado na gestão de crédito conseguem reduzir em até 30% as perdas com inadimplência, além

de acelerar o ciclo de recebíveis. Da mesma forma, um estudo publicado no *Journal of Financial Services Research* (Ngai et al., 2021) ressalta que a integração de dados internos e externos (como histórico de pagamentos e variáveis macroeconômicas) permite prever comportamentos de default com maior acurácia.

Outro trabalho relevante, de Wamba et al. (2023), publicado no *International Journal of Information Management*, destaca que a inteligência analítica aplicada à cobrança proporciona: Maior eficiência na priorização de contas a recuperar. redução de custos operacionais com estratégias direcionadas e melhoria na experiência do cliente por meio de abordagens personalizadas. Diante dessas evidências, formula-se a **Proposição 1: A utilização de ferramentas de Data Analytics na gestão do Crédito e Cobrança pode aprimorar a capacidade dos gestores financeiros em tomar decisões estratégicas.**

A análise de grandes conjuntos de dados e o uso de técnicas avançadas de análise têm se mostrado eficazes na identificação de padrões, tendências financeiras que podem levar a melhorias operacionais. A utilização de ferramentas de *Data Analytics* na gestão financeira resultou em melhorias na eficiência. Conforme citado anteriormente, a análise de desempenho financeiro baseada em dados não apenas melhora a eficiência operacional, mas também contribui para a sustentabilidade a longo prazo das organizações (Bodjov, 2018).

McAfee e Brynjolfsson (2012) ressaltam a capacidade do *Data Analytics* de transformar a maneira como as empresas tomam decisões estratégicas. A análise de *Data Analytics* fornece informações detalhadas sobre os processos financeiros, permitindo uma gestão mais eficiente dos recursos e uma alocação mais precisa dos investimentos.

Kim e Lee (2017) destacam como as capacidades de análise de *Data Analytics* podem influenciar positivamente o desempenho organizacional como um todo. Conforme Gupta e George (2016), a utilização de *Data Analytics* permite que as empresas realizem análises mais detalhadas e precisas dos dados financeiros, o que pode contribuir para uma melhor compreensão do desempenho financeiro da empresa e para uma tomada de decisão mais fundamentada e estratégica.

McAfee et al. (2012) discutem o impacto do *Data Analytics* na gestão empresarial e destacam como as empresas que adotam o uso inteligente de *Data Analytics* podem alcançar melhorias significativas na eficiência e na tomada de decisões financeiras. Chen, Chiang & Storey (2012) fornecem exemplos práticos de como as organizações podem aproveitar o poder do *Data Analytics* para tomar decisões mais informadas e eficientes. Chen, Mao & Liu (2014) abordam conceitos, desafios e aplicações, destacam como a análise de *Data Analytics* pode levar a melhorias na eficiência das organizações, incluindo a gestão financeira.

O estudo de Ward e Barker (2013) enfatiza a capacidade do *Data Analytics* de fornecer dados e informações detalhadas que permitem uma melhor gestão dos recursos financeiros das organizações, argumento também encontrado na pesquisa da Ernst e Young (2023). Luo, Kizito & Huang (2018), ao realizar revisão literária sobre o tema, concluem que a utilização de *Data Analytics* pode levar a melhorias na eficiência operacional e financeira, resultando em um desempenho geral aprimorado. E, por fim, segundo um estudo de Roberts e Taylor (2022), além de melhorar a capacidade de identificar fraudes financeiras, o uso de *Data Analytics* aumenta a eficiência, uma necessidade crescente diante de transações cada vez mais complexas no mercado financeiro.

A partir destes argumentos, propõe-se a **Proposição 2: A utilização de ferramentas de Data Analytics na gestão do Crédito e Cobrança pode resultar em melhorias na eficiência.**

A utilização de ferramentas de *Data Analytics* na gestão financeira, além de levar a uma melhoria na identificação de padrões, é também respaldada por pesquisas e estudos recentes. O uso de técnicas avançadas de análise de dados em grandes volumes de informações permite identificar padrões ocultos que podem ser aplicados na gestão financeira.

Sanders (2016) afirma que a previsão de demanda está mudando no que tange a conseguir informações mais precisas em relação à previsão de demanda, apoiando assim a companhia a tomar decisões em um tempo que permite manobras operacionais e financeiras mais rápidas. No estudo

de Shen, Lin e Zhang (2015), é explorado o uso de redes neurais de retropropagação para prever índices de ações, evidenciando a capacidade do *Data Analytics* de identificar tendências relevantes e de apoiar a tomada de decisões financeiras informadas. McAfee e Brynjolfsson (2012) enfatizam como a análise de *Data Analytics* pode ajudar na identificação de tendências e padrões significativos, permitindo uma melhor tomada de decisões financeiras.

Em artigo publicado na revista Science, Lazer et al. (2014) discutem as armadilhas e desafios na aplicação de *Data Analytics*. Embora o foco principal seja na detecção de doenças, as lições aprendidas são aplicáveis a outras áreas, incluindo a gestão financeira, destacando a importância da identificação adequada de padrões nos dados. Chen, Mao e Liu (2014) destacam como as técnicas de análise de dados podem melhorar a identificação de padrões e tendências relevantes na gestão financeira, argumento corroborado por Sivarajah et al. (2017), que discutem como as técnicas de análise podem ajudar a identificar padrões e ideias relevantes para a gestão financeira eficaz.

Ahmed et al. (2016) destacam a importância de uma agenda de pesquisa inclusiva no campo do *Data Analytics*, que permita a exploração de diferentes técnicas e abordagens para identificar e entender os padrões ocultos nos dados financeiros. Aliado a isso a utilização de ferramentas de *Data Analytics* na gestão financeira resultou em uma melhoria na identificação de tendências.

De acordo com Chen, Chiang e Storey (2012), a análise avançada de dados pode revelar relações e tendências não perceptíveis a olho nu, proporcionando percepções relevantes para a gestão financeira. Destacamos ainda que a detecção de risco de crédito é uma área crítica na gestão financeira, e a utilização de ferramentas de *Data Analytics* pode revelar padrões ocultos que podem ser aplicados nesse contexto.

Assim sendo, propõe-se a **Proposição 3: A utilização de ferramentas de *Data Analytics* na gestão financeira pode resultar em uma melhoria na identificação de padrões.**

2.6.1. Sumário das Proposições de Pesquisa

A Tabela 6 resume esta seção e relaciona as proposições elaboradas para a investigação do tema de pesquisa, bem como as fontes de base para o estudo.

Tabela 6

Proposições de pesquisa

Proposição	Descrição	Fonte
P1	Proposição 1: A utilização de ferramentas de <i>Data Analytics</i> na gestão do Crédito e Cobrança Pode aprimorar a capacidade dos gestores financeiros em tomar decisões estratégicas.	Waller e Fawcet (2013), Gandomie Haider (2015), Ahmed et al. (2016), Turban & Volonino (2017), Kache e Seuring, (2017), Gartner (2020), Barua (2024),
P2	Proposição 2: A utilização de ferramentas de <i>Data Analytics</i> na gestão do Crédito e Cobrança pode resultar em melhorias na eficiência.	Baldo (2022), McAfee et al. (2012), Assis & Decoster (2025), Chen, Chiang & Storey (2012), Ward e Barker (2013) Chen, Mao & Liu (2014), Gupta & George (2016), Kim e Lee (2017), Bodjov (2018), Luo, Kizito & Huang (2018), Roberts e Taylor (2022), Ernst e Young (2023).

P3	Proposição 3: A utilização de ferramentas de <i>Data Analytics</i> na gestão do Crédito e Cobrança pode auxiliar na identificação de padrões com vistas à redução de inadimplência e à melhoria do fluxo de caixa	Silva, J., & Santos, M. (2020), May, V. A, & Crotti, Y.(2024), Assis & Decoster (2025)Chen, Chiang e Storey (2012), McAfee e Brynjolfsson (2012), Lazer et al. (2014), Chen, Mao e Liu (2014) Shen, Lin e Zhang (2015), Ahmed et al. (2016) Sanders (2016), Sivarajah et al. (2017)
----	---	---

Fonte: Dados da pesquisa

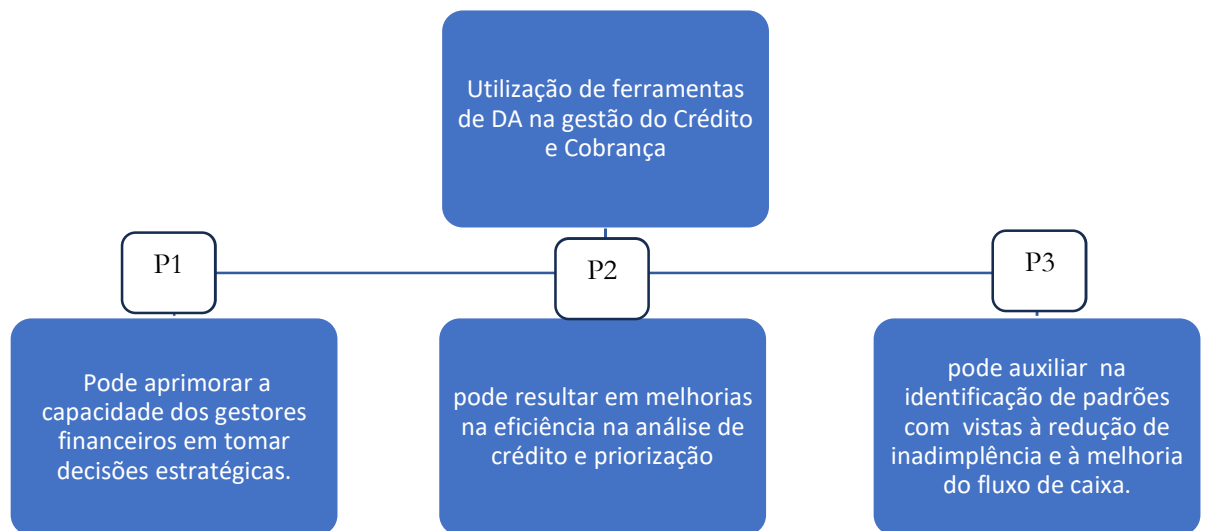


Figura 1. Fluxograma de proposições

3. MÉTODOS

Este estudo caracteriza-se como pesquisa-ação que é uma forma de investigação-ação que utiliza técnicas de pesquisa consagradas para informar a ação que se decide tomar para melhorar a prática (Tripp,2005). Sendo assim, busca detalhar e analisar o efeito do emprego de ferramentas de *Data Analytics* na administração financeira de um conglomerado empresarial que comercializa acumuladores elétricos. A natureza da pesquisa é qualitativa, uma vez que se propõe a compreender os fenômenos observados a partir de uma perspectiva interpretativa e subjetiva (Gil, 2019).

Sobre a pesquisa-Ação, este é um tipo de abordagem que busca unir a pesquisa à ação (à prática), e com isso produzir conhecimento (Jönsson, 2010;Tripp, 2005), e é considerada a precursora da pesquisa Intervencionista em ciências sociais. Com algumas variações na metodologia, a pesquisa-Ação, em geral, segue um ciclo de melhoria e resolução de problemas (Tripp, 2005), com algumas etapas estabelecidas. Trata-se de uma investigação de campo a partir da participação conjunta do pesquisador e dos envolvidos no processo no qual a intervenção ocorre. A pesquisa Intervencionista é uma variação da pesquisa Ação (Jönsson, 2010; Lukka e Vinnari, 2017).

A revisão da literatura especializada demonstra que existem diversas perspectivas metodológicas para a condução de pesquisas-ação (Thiollent, 2009; Tripp, 2005; Vergara, 2005).Este estudo seguirá a estrutura de Trupp (2005), que segundo este autor a pesquisa-ação é termo amplo que designa qualquer metodologia baseada em um ciclo contínuo de aprimoramento da prática por meio da alternância sistemática entre ação e reflexão (Figura 2). Nesse processo, o pesquisador planeja, implementa, descreve e avalia mudanças com o objetivo de melhorar sua prática, adquirindo, ao longo do caminho, conhecimentos tanto sobre a própria prática quanto

sobre os métodos de investigação. Esse enfoque permite que a ação seja constantemente refinada a partir de dados coletados e analisados, promovendo um aprendizado dinâmico e contextualizado. A investigação-ação, portanto, não se limita a uma simples aplicação de teorias, mas envolve um engajamento crítico e reflexivo, no qual a prática é transformada e compreendida de maneira mais profunda (Tripp,2005).

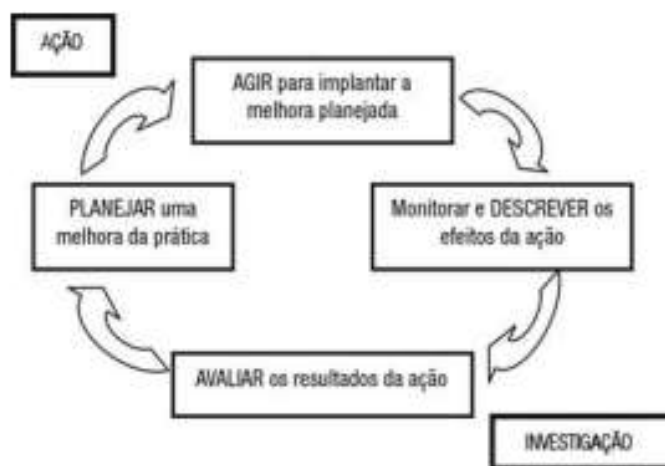


Figura 2. Fluxo de Intervenção

Fonte: (Tripp 2005)

A pesquisa-ação, como uma de suas vertentes, destaca-se por seu caráter participativo e colaborativo, frequentemente envolvendo os sujeitos da pesquisa no processo de investigação. Dessa forma, ela não apenas busca resolver problemas concretos, mas também contribui para o desenvolvimento teórico e metodológico, fortalecendo a relação entre teoria e prática. Sua natureza cíclica e adaptativa a torna especialmente útil em contextos educacionais, organizacionais e sociais, onde a complexidade das situações exige abordagens flexíveis e reflexivas (Tripp,2005).

Este estudo segue a modalidade de pesquisa-ação técnica conforme a abordagem de Tripp (2005), a qual é constituída por uma abordagem pontual na qual o pesquisador toma uma prática existente de algum outro lugar e a implementa em sua própria esfera de prática para realizar uma melhora. A metodologia de Tripp (2005) apresenta uma estrutura com as seguintes etapas: 1. Reconhecimento da situação, dos participantes (o próprio e outros), das práticas profissionais atuais, da intencionalidade e do foco temático; 2. Planejamento da preocupação temática (ou ciclo anterior) ao primeiro passo de ação; 3. Implementação: relato discursivo sobre quem fez o quê, quando, onde, como e por quê; e 4. Avaliação. Adicionalmente o estudo aqui desenvolvido propôs uma metodologia de abordagem quase-experimental, segmentando os estabelecimentos do grupo em dois grupos distintos: um grupo de intervenção, que será submetido à aplicação das ferramentas de *Data Analytics* que chamaremos de pós – intervenção , e um de controle grupo pré-intervenção, que manterá os procedimentos convencionais de administração financeira.

A escolha pelo método intervencionista justifica-se pela necessidade de investigar como uma intervenção específica pode influenciar os resultados financeiros de maneira mensurável. Daí este estudo tem como base o estudo de Toaldo, Vallim Filho, Oyadomari e Mendonça Neto (2024), que utilizando o conceito de pesquisa intervencionista procura validar modelos de aprendizado de máquina por meio de um experimento planejado de campo, seguido de análise estatística.

Além disso, a pesquisa baseia-se em referências metodológicas consagradas, como os trabalhos de Gil (2019) e Vergara (2015), que fornecem diretrizes sobre a condução de pesquisas qualitativas e intervencionistas. A abordagem qualitativa permite uma análise aprofundada dos dados coletados, proporcionando uma compreensão mais rica e detalhada dos fenômenos

estudados. Para garantir a confiabilidade e validação interna da interpretação dos dados, o estudo se baseia em múltiplas fontes de evidência, o que permite a triangulação ou convergência ao final da análise (Yin, 2001).

A triangulação de dados constitui um elemento central desta pesquisa, por permitir a convergência de diferentes fontes e perspectivas para aumentar a robustez, confiabilidade e validade das conclusões. Ao integrar informações provenientes de levantamento documental, observação participante e entrevistas estruturadas e semiestruturadas, a triangulação possibilita não apenas a confirmação de evidências, mas também a identificação de discrepâncias e nuances que poderiam passar despercebidas em uma única fonte de dados. Conforme Yin (2001, p.120), a utilização simultânea de múltiplas fontes reforça a consistência das constatações, proporcionando uma compreensão mais profunda e contextualizada dos fenômenos investigados. Assim, a triangulação não se limita a um cruzamento de dados, mas atua como um mecanismo metodológico que fortalece a análise interpretativa e garante que as conclusões derivem de um processo de investigação rigoroso e sistemático.

3.1 Coleta de dados

A coleta de dados desenvolveu-se pela triangulação de dados, que segundo Yin (2001, p 120), fundamenta-se na lógica de se utilizar várias fontes de evidências, conduzindo a uma convergência explicitada conforme parte superior da Figura 3. As técnicas utilizadas no estudo foram (i) levantamento de documentos; (ii) observação participante, (iii) entrevistas semiestruturadas e entrevista estruturada. Ou seja, a partir da coleta de dados de diferentes perspectivas e de diferentes fontes, por meio do cruzamento de uma fonte com a outra, a “constatação é mais forte e melhor sustentada” (Eisenhardt, 1989).

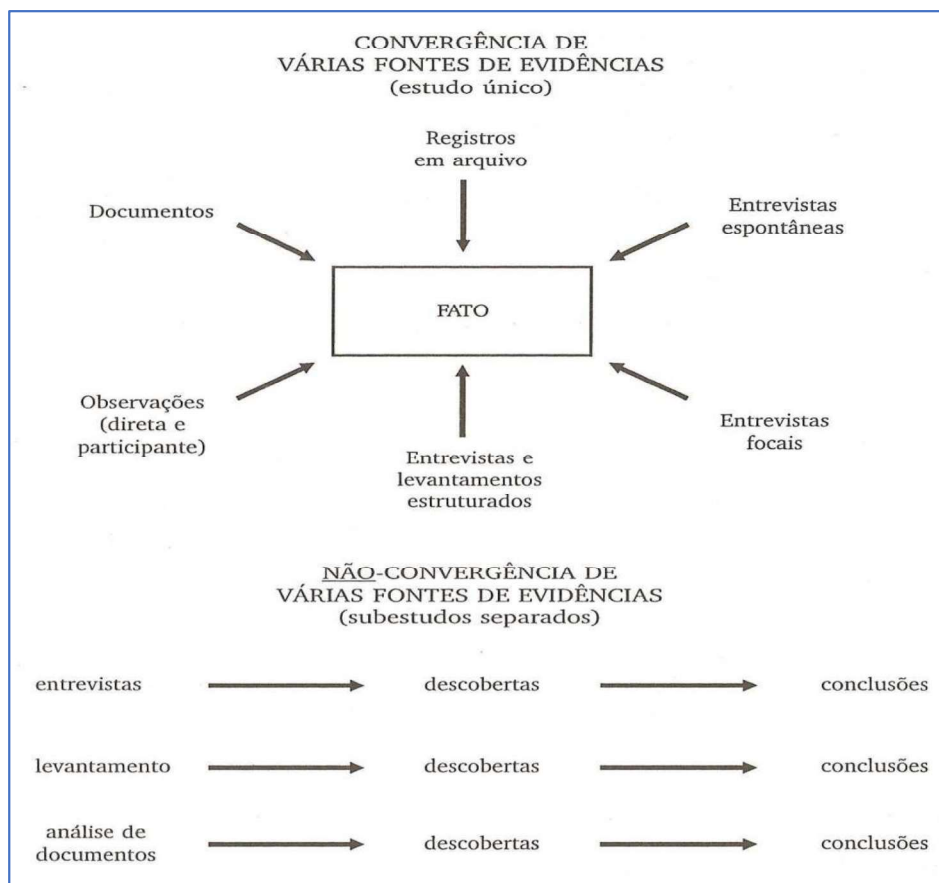


Figura 3. Convergência e não-convergência de várias fontes de evidências.
Fonte: Yin (2001, p.122)

Para a coleta de dados secundários, foram utilizadas a técnica de levantamento bibliográfico e o procedimento de revisão sistemática da literatura, a fim de compreender o estado da arte sobre o tópico abordado (Treinta et al., 2013). Além da observação participante, apontada por Minayo (2008) como a técnica mais utilizada nas pesquisas de natureza qualitativa, a coleta de dados primários também foi realizada, por meio de questionário estruturado com colaboradores sujeitos à intervenção, como também entrevistas online via Microsoft teams com gestores de crédito e cobrança. Na técnica de observador participante, o observador faz parte da vida dos observados e assim é parte do contexto sob observação. Para a definição da estratégia de coleta de dados, foi desenvolvida uma survey no 1º. Caso e no 2º. Caso foi desenvolvido um roteiro de pesquisa, detalhando todas as variáveis a serem consideradas (Yin, 2001).

3.1.1 Questionário para colaboradores

Além da vertente quantitativa baseada em métricas financeiras objetivas, esta pesquisa incorporou um questionário estruturado para compreender a percepção dos colaboradores na etapa pós-intervenção diretamente envolvidos na aplicação das ferramentas analíticas através do Microsoft forms via e-mail para os colaboradores que participaram do treinamento — especificamente o Painel do Power BI e o algoritmo automatizado de limite de crédito. Com o intuito de avaliar a usabilidade, aceitação, integração e impacto prático desses instrumentos nas rotinas profissionais, foi desenvolvido e aplicado um questionário estruturado composto por seis questões objetivas em escala Likert de 11 pontos, variando de 0 (nenhuma contribuição ou satisfação) a 10 (máxima contribuição ou satisfação). A aplicação deste instrumento foi direcionada exclusivamente aos 73 participantes que integraram as três turmas de treinamento e que, após capacitação teórica e prática, passaram a operar efetivamente as ferramentas nas suas respectivas unidades.

A construção do questionário teve como base analítica os fundamentos de usabilidade em sistemas interativos (Nielsen, 2003) e conceitos de avaliação de impacto tecnológico em processos decisórios (Davenport, 2018), sendo também ancorada nos objetivos específicos da intervenção proposta neste estudo. As assertivas foram formuladas com clareza e precisão, abordando eixos centrais da experiência do usuário com a tecnologia: (1) efetividade operacional, (2) velocidade e economia de tempo, (3) acesso a informações relevantes, (4) impacto sobre os indicadores de inadimplência, (5) grau de integração das ferramentas aos processos existentes e (6) predisposição à difusão da inovação. Esses aspectos foram intencionalmente escolhidos para abranger tanto os efeitos diretos da intervenção sobre o desempenho das atividades de crédito e cobrança quanto percepções subjetivas relacionadas à adoção e recomendação futura das soluções implementadas.

A primeira assertiva buscou mensurar o grau de eficiência percebida pelos usuários na priorização de clientes para cobrança com base na classificação de risco exibida no Painel do Power BI. Esperava-se, com essa métrica, verificar se a introdução da análise preditiva e da visualização interativa dos dados proporcionou maior assertividade e foco nas ações de cobrança. A segunda assertiva concentrou-se na automatização da análise de crédito, avaliando se a adoção de um algoritmo preditivo resultou em economia de tempo e redução de subjetividades no processo decisório. A terceira assertiva explorou a facilidade de acesso às informações por meio dos dashboards analíticos e sua contribuição para decisões mais rápidas e baseadas em dados atualizados — elemento crucial para contextos operacionais dinâmicos, como o da empresa Alfa.

Por sua vez, a quarta assertiva procurou compreender o grau de percepção dos profissionais sobre o impacto das ferramentas na redução da inadimplência em suas unidades ou regiões. Essa assertiva tem papel fundamental na triangulação qualitativa dos dados financeiros, pois permite verificar se a melhoria nos indicadores de performance reflete também uma mudança cultural na percepção de eficácia dos processos. A quinta assertiva investigou o nível de adaptabilidade das soluções digitais ao fluxo de trabalho pré-existente, especialmente em relação à substituição das tradicionais planilhas manuais, ainda fortemente enraizadas nos processos operacionais da

organização. Por fim, a sexta assertiva teve caráter prospectivo, ao solicitar dos respondentes uma nota sobre sua disposição em recomendar a expansão das ferramentas para outras unidades do conglomerado, permitindo avaliar o grau de aprovação e replicabilidade percebida da intervenção. As assertivas estão relacionadas na Tabela 7.

Tabela 7

Questionário estruturado

Questão	Assertivas
1	O painel do Power BI (classificação de títulos por risco) melhorou a eficiência na priorização de clientes para cobrança.
2	O algoritmo automatizado de limite de crédito reduziu o meu tempo gasto na análise e concessão de crédito
3	Os dashboards do Power BI facilitaram o acesso a informações atualizadas para decisões rápidas.
4	As ferramentas contribuíram para a redução da inadimplência na minha unidade/região.
5	As ferramentas foram adaptadas aos processos existentes.
6	Recomendaria a expansão dessas ferramentas para outras unidades da empresa.

Fonte: Baseado em Nielsen (2003) e Davenport (2018)

3.1.2 Formulários de entrevista

Com base nas interações e no delineamento metodológico previamente discutido para a dissertação, a etapa qualitativa da pesquisa incluiu a realização de entrevistas com 13 gestores financeiros, cada um representando uma empresa localizada nas regiões previamente selecionadas para a intervenção. Essa amostra foi escolhida de forma intencional e estratégica, buscando contemplar diferentes contextos organizacionais e operacionais, possibilitando uma análise mais robusta e abrangente da percepção dos gestores quanto aos impactos da adoção de ferramentas de *Data Analytics* na gestão financeira no processo de crédito e cobrança.

As entrevistas foram realizadas 12 meses após o início da intervenção com *Data Analytics*, período considerado adequado para que os gestores possam vivenciar os efeitos da implementação das ferramentas analíticas no ambiente corporativo e, conseqüentemente, tenham subsídios concretos para avaliar suas contribuições. A escolha desse intervalo temporal tem fundamento na literatura sobre inovação organizacional e mudanças tecnológicas, que destaca a importância de um período mínimo para que os impactos sejam percebidos de maneira mais precisa e menos suscetível a variáveis transitórias.

O roteiro de entrevista é semiestruturado, permitindo tanto a coleta de dados comparáveis entre os entrevistados quanto a liberdade para que cada gestor aborde aspectos específicos de sua realidade e de sua experiência com a intervenção.

Ao considerar a perspectiva dos gestores financeiros que vivenciaram diretamente a intervenção, a pesquisa busca ampliar a compreensão sobre os impactos práticos da aplicação de *Data Analytics* na gestão financeira, contribuindo com a literatura e oferecendo informações para a tomada de decisão em empresas que pretendem adotar soluções similares.

Na tabela 8 é apresentado o roteiro das entrevistas com os gestores.

Tabela 8

Roteiro de pesquisa qualitativa

Perguntas por tópicos relacionados às proposições de pesquisa	Artigos de referência
1 - Capacidade dos gestores financeiros em tomar decisões estratégicas no processo de crédito e cobrança.	Assis, A. G. de, & Decoster, S. R. A. (2025).
1.1 Como o uso de ferramentas de <i>Data Analytics</i> tem influenciado suas decisões estratégicas relacionadas ao crédito e à cobrança?	

1.2	Quais mudanças você percebeu na qualidade e na agilidade das informações disponíveis para tomada de decisão desde a adoção dessas ferramentas?	
1.3	Você acredita que o Data Analytics trouxe novos indicadores ou perspectivas para a gestão do crédito e da cobrança? Poderia citar exemplos?	
1.4	Quais desafios ou limitações você enfrenta ao utilizar essas ferramentas no dia a dia para apoiar suas decisões?	
2 - Melhorias na eficiência na análise de crédito e priorização de clientes na cobrança		Baldo (2022), McAfee et al. (2012), Chen, Chiang & Storey (2012).
2.1	De que forma as ferramentas de Data Analytics impactaram o tempo gasto na análise de crédito na sua rotina?	
2.2	Como o uso dessas ferramentas tem contribuído para definir quais clientes devem ser priorizados no processo de cobrança?	
2.3	Quais mudanças você notou no fluxo de trabalho da equipe desde a utilização de ferramentas de Data Analytics?	
2.4	Existem situações em que, mesmo com o uso de Data Analytics, o tempo de análise ou priorização ainda é um desafio?	
2.5	De que maneira as ferramentas de Data Analytics têm contribuído para identificar diferentes perfis de clientes devedores?	
2.6	Quais critérios ou informações fornecidas pelo Data Analytics você considera mais relevantes para uma segmentação de clientes eficiente?	
3 - Identificação de padrões com vistas à redução de inadimplência e à melhoria do fluxo de caixa nas organizações.		Silva, J., & Santos, M. (2020), May, V. A, & Crotti, Y.(2024)
3.1	O uso de Data Analytics trouxe melhorias perceptíveis na gestão do fluxo de caixa? Poderia dar exemplos?	
3.2	Desde a implementação de ferramentas de Data Analytics, quais mudanças você percebeu nos índices de inadimplência da empresa?	
3.3	Quais indicadores ou resultados você considera mais relevantes para avaliar o impacto do Data Analytics no crédito e cobrança?	
3.4	Existem fatores que dificultam a obtenção de resultados consistentes com o uso de Data Analytics?	

3.2. Análise de dados

Após a transcrição das entrevistas, as análises dos dados foram realizadas utilizando análise de conteúdo temática, com o intuito de posterior interpretação das mesmas, extraindo assim o sentido mais amplo das respostas obtidas mediante a ligação dessas com os conhecimentos e conceitos obtidos a partir da intervenção. Para Bardin (2009), a análise de conteúdo temática é organizada em torno de três polos: 1. a pré-análise; 2. a exploração do material; e, por fim, 3. a tratamento dos resultados: a inferência e a interpretação. Na fase da exploração do material, Bardin (2009) ressalta que a análise do material exige sua codificação, ou seja, sua transformação de dados brutos dos textos por recortes, agregação ou enumeração. Para codificação, pode-se usar palavras, temas, contextos, relações, personagens, etc., até se chegar à categorização dos mesmos. Sugere-se aqui utilizar a modalidade temática, que enfatiza o “tema”, como já foi exposto anteriormente. A

categorização é uma operação de classificação de elementos constitutivos de um conjunto por diferenciação e em seguida por reagrupamento segundo o gênero (analogia), com os critérios previamente estabelecidos

Sendo assim, foram identificadas as categorias recorrentes e padrões interpretativos que permitam compreender como os gestores avaliam os efeitos da intervenção tecnológica no desempenho da área financeira. Esta etapa qualitativa tem como intuito complementar os resultados quantitativos obtidos ao longo da pesquisa, como também permitir identificar fatores contextuais, resistências culturais ou operacionais e boas práticas que eventualmente não seriam captadas por meio de indicadores numéricos.

3.3. Empresa Alfa

O conglomerado empresarial selecionado para o estudo, denominado Alfa para fins de confidencialidade, foi fundado em 1957 como uma fábrica de baterias automotivas e conta atualmente com 82 estabelecimentos presentes em 25 estados brasileiros e no Distrito Federal formando um conglomerado empresarial de 54 empresas. A parte operacional e gestão financeira de cada unidade é autônoma, entretanto possuem o mesmo sistema de gestão empresarial (ERP), mesmas normas de governança e acesso a dados. O estudo irá analisar as métricas financeiras, tais como inadimplência, fluxo de caixa e resultados financeiros, antes e após a intervenção. O grupo empresarial hoje conta com mais de 6 mil colaboradores e faturou no exercício de 2024 o montante de 3 bilhões de reais com crescimento de 20% em relação ao exercício do ano anterior.

A empresa diversificou sua atuação, produzindo baterias e sistemas de armazenamento de energia para uma ampla gama de aplicações, incluindo motocicletas, embarcações, equipamentos industriais como empilhadeiras, sistemas de nobreaks, transporte público como metrô e trens, além de infraestruturas de telecomunicações, entre outros segmentos.

3.4. Reconhecimento

Segundo Tripp (2005), o reconhecimento consiste em uma análise situacional que oferece uma visão abrangente do contexto da pesquisa-ação, das práticas atuais e dos participantes envolvidos. Assim como no processo de projetar e implementar mudanças para aprimorar a prática, o reconhecimento segue o mesmo ciclo da pesquisa-ação: planeja-se como monitorar e avaliar a situação atual, executa-se essa avaliação e, em seguida, interpretam-se e analisam-se os resultados. Na tabela 9 são relacionados os processos da organização Alfa, analisados na situação anterior e com o uso de ferramentas de *Data Analytics*:

Tabela 9

Processos com intervenção

ID	Processo	Como funciona
Processo 1	Cobrança	Extração diária do ERP da posição do contas a receber.
Processo 2	Liberação de crédito	Concedido com base no patrimônio líquido do cliente.

Fonte: Dados da pesquisa

3.4.1. Reconhecimento da situação – Processo de cobrança

O processo de cobrança na organização Alfa é realizado de forma sistemática e diária, com o objetivo de garantir a recuperação de valores em aberto e a manutenção da saúde financeira da empresa. O procedimento inicia com a extração diária de relatórios diretamente do sistema ERP.

Esses relatórios contêm dados detalhados sobre os títulos em aberto, incluindo informações sobre os clientes, valores devidos, prazos de vencimento e status de pagamento. A extração é feita de forma abrangente, sem priorização específica de quais títulos devem ser cobrados primeiro.

3.4.2. Reconhecimento da situação – Processo de Crédito

A primeira etapa do processo ocorre somente após a aprovação do cadastro do cliente, que é pré-requisito indispensável para qualquer análise de crédito. Uma vez aprovado o cadastro, a concessão de crédito é avaliada com base em critérios específicos, que incluem: o tempo de constituição da empresa, verificando se a empresa possui histórico e estabilidade no mercado; a integralização do Capital Social, onde se confirma se o valor total do Capital Social foi devidamente integralizado; e a análise de 10% do limite do Capital Social para clientes com sugestão de crédito de até R\$ 20.000, com base em uma análise prévia. Além disso, é realizada uma análise da empresa no mercado, considerando sua reputação, histórico financeiro e desempenho comercial.

3.4.3. Reconhecimento da situação – Participantes

A amostra deste estudo é composta por colaboradores da organização Alfa em diferentes níveis de experiência organizacional e formação acadêmica, todos com exposição a ferramentas de Data Analytics em suas funções. No total são 145 colaboradores que executam as atividades de crédito e cobrança nas 82 unidades, espalhadas pelo Brasil.

3.4.3.1 Tempo de serviço dos participantes na organização

Os participantes foram classificados em quatro categorias temporais, conforme sua permanência na empresa. Foram classificados em 4 grupos: abaixo de 1 ano, contratados entre 1 ano e 1 mês a 2 anos, contratados entre 2 anos e 1 mês a 4 anos, e contratados a mais de 4 anos, conforme figura 4.



Figura 4. Distribuição de tempo de serviço dos participantes

A maioria (55,0%) concentra-se na faixa de 6 meses a 3 anos de vínculo, indicando um equilíbrio entre profissionais em fase de adaptação e outros já consolidados.

3.4.4. Reconhecimento das práticas profissionais atuais – Processo de cobrança

Após a extração dos dados do sistema ERP, as informações são organizadas e transferidas para uma planilha padrão (figura 6), que serve como ferramenta central para o gerenciamento das cobranças. Essa planilha é estruturada de forma a incluir os seguintes campos essenciais: Nome do Cliente, que identifica de quem se está cobrando; Valor em Aberto, que representa o montante total devido pelo cliente; Quantidade de Dias em Aberto, que indica o tempo decorrido desde o vencimento do título; e Quantidade de Títulos, que mostra o número de títulos pendentes para cada cliente. A transferência dos dados para a planilha é feita de forma manual, copiando e colando as informações do ERP para a planilha, garantindo que todos os dados estejam atualizados e precisos.

Com base nas informações contidas na planilha, a equipe de cobrança inicia o processo de contato com os clientes. Esse contato pode ser realizado por meio de diversos canais, como telefone, e-mail ou whatsapp, dependendo da política da empresa e do perfil do cliente. O objetivo é negociar a regularização dos pagamentos pendentes, seja por meio do pagamento integral, do parcelamento da dívida ou de outras formas de acordo que sejam viáveis para ambas as partes. Durante o contato, a equipe de cobrança utiliza as informações da planilha para embasar suas negociações, apresentando ao cliente os valores exatos devidos, o tempo de atraso e o número de títulos pendentes.

Após o contato com os clientes, a planilha é atualizada com as informações sobre o andamento das cobranças. Caso um acordo seja firmado, as informações sobre o parcelamento ou nova data de pagamento são registradas na planilha para acompanhamento futuro. Essa atualização é essencial para manter a planilha sempre atualizada e garantir que todas as pendências sejam monitoradas de perto.

Além disso, o processo de cobrança inclui o acompanhamento diário das novas pendências que surgem. Como os relatórios são extraídos diariamente do sistema ERP, a planilha é constantemente alimentada com novos dados, permitindo que a equipe de cobrança identifique rapidamente qualquer novo título em aberto e tome as medidas necessárias para sua regularização. Esse acompanhamento contínuo é fundamental para evitar que as pendências se acumulem e para garantir que a empresa mantenha um fluxo de caixa saudável.

Por fim, o processo de cobrança é documentado e monitorado de perto pela equipe financeira, que utiliza a planilha padrão como ferramenta principal para o controle e a gestão das cobranças. Relatórios periódicos são gerados com base nas informações contidas na planilha, permitindo que a liderança da empresa tenha uma visão clara e detalhada da situação financeira e do desempenho das ações de cobrança. Esses relatórios são utilizados para identificar tendências, avaliar a eficácia das estratégias de cobrança e implementar melhorias no processo, sempre com o objetivo de maximizar a recuperação de valores em aberto e minimizar a inadimplência. O fluxograma de atividades é apresentado na Figura 5:

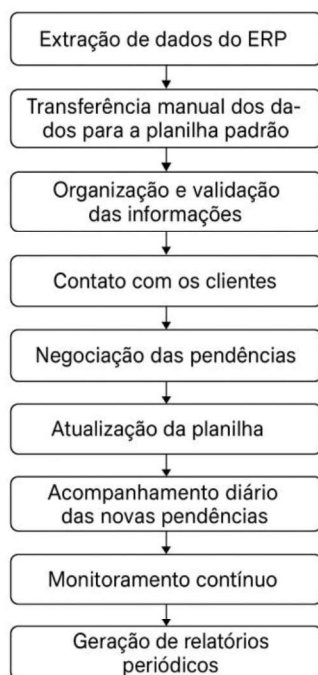


Figura 5 Fluxo das atividades do processo de cobrança

Cliente	Nota fiscal	Vencimento	Valor em aberto	Dias em atraso	Status Cobrança
0304539	000451784	29/11/2024	192,80	207	Tentativa de contato sem sucesso, whatsapp sem retorno. Vendedor cliente.
0185285	010415551	01/04/2024	771,19	449	Tentativa de contato sem sucesso, whatsapp sem retorno. Vendedor cliente.
0210623	010413298	15/03/2024	3.391,24	466	Tentativa de contato sem sucesso, whatsapp sem retorno. Vendedor cliente.
0219565	010446310	21/10/2024	2.675,42	246	Tentativa de contato sem sucesso, whatsapp sem retorno. Vendedor cliente.
0214192	000467765	26/03/2025	55,37	90	Liquidado
0219693	010447328	28/10/2024	441,95	239	Tentativa de contato sem sucesso, whatsapp sem retorno. Vendedor cliente.
0317958	000485572	17/07/2025	2.105,93	-23	Saldos a vencer
0064164	000483396	02/07/2025	2.105,93	-8	Saldos a vencer
0316519	000480840	18/06/2025	2.105,93	6	Cliente solicitou coleta do saldo
0219096	000475070	10/05/2025	963,98	45	Cliente solicitou coleta do saldo
0189486	000474991	10/05/2025	941,24	45	Tentativa de contato sem sucesso, whatsapp sem retorno. Vendedor cliente.
0113445	000470025	10/04/2025	1.046,04	75	Cliente solicitou coleta do saldo
0315475	000477832	29/05/2025	963,98	26	Cliente solicitou coleta do saldo
0316643	000481370	20/06/2025	1.070,76	4	Tentativa de contato sem sucesso, whatsapp sem retorno. Vendedor cliente.
0316279	000480870	18/06/2025	1.070,76	6	Tentativa de contato sem sucesso, whatsapp sem retorno. Vendedor cliente.
0063876	010408462	07/02/2024	27,68	503	Cliente solicitou coleta do saldo
0212474	000480507	14/06/2025	801,84	10	Tentativa de contato sem sucesso, whatsapp sem retorno. Vendedor cliente.
0064105	000483491	02/07/2025	1.968,50	-8	Saldos a vencer
0064000	000471673	20/04/2025	101,84	65	Tentativa de contato sem sucesso, whatsapp sem retorno. Vendedor cliente.
0084908	000481467	21/06/2025	1.086,58	3	Tentativa de contato sem sucesso, whatsapp sem retorno. Vendedor cliente.
0313016	000472843	26/04/2025	308,47	59	Tentativa de contato sem sucesso, whatsapp sem retorno. Vendedor cliente.
0218456	000477615	28/05/2025	403,39	27	Saldos a vencer
0313485	000472917	26/04/2025	385,59	59	Saldos a vencer
0212483	000474523	07/05/2025	91,95	48	Tentativa de contato sem sucesso, whatsapp sem retorno. Vendedor cliente.
0202954	000470104	10/04/2025	883,90	75	Saldos a vencer
0212096	000450542	21/11/2024	960,03	215	Tentativa de contato sem sucesso, whatsapp sem retorno. Vendedor cliente.
0218050	000461968	14/02/2025	19,77	130	Tentativa de contato sem sucesso, whatsapp sem retorno. Vendedor cliente.

Figura 6 Planilha de cobrança

3.4.5. Reconhecimento das práticas profissionais atuais – Concessão de crédito

Durante os três meses iniciais após a concessão do crédito, o limite estabelecido não poderá ser ultrapassado, garantindo um período de avaliação e adaptação. Após esse período, é realizada uma revisão do limite de crédito e da performance de pagamento do cliente, que pode resultar em um aumento ou redução do limite inicial, dependendo do comportamento do cliente. A liberação do crédito, em nenhuma hipótese, poderá ser superior ao limite estabelecido. Caso o cliente solicite um pedido acima do limite de crédito, a liberação só poderá ser autorizada pelo Supervisor Administrativo/Financeiro ou pelo Gerente da Unidade, mediante uma nova análise de crédito que avalie a viabilidade da solicitação.

O processo também prevê a atualização anual da análise de limite de crédito do cliente, garantindo que as informações estejam sempre alinhadas com a realidade financeira e comercial do cliente.

3.5 Reconhecimento da Intencionalidade

Nesta seção descreve-se as técnicas de *Data Analytics* desenvolvidas e utilizadas na intervenção, onde com o apoio de técnicas de aprendizado de máquina utilizou-se a plataforma do *Data Bricks* em virtude de sua versatilidade por ser compatível com linguagem *SQL*, *Python* e *R* para o desenvolvimento da modelagem preditiva. Na tabela 10 é possível visualizar a relação entre as proposições, os processos pós-intervenção e as técnicas de *analytics* implementadas nas unidades. Na seção de implementação são apresentados os modelos utilizados com a devida explicação da técnica utilizada.

Tabela 10

Técnicas de *analytics* implementadas

Proposições	Processo Com Intervenção	Técnica
P1	Painel em Power BI com os títulos classificados por risco de recebimento (do maior para o menor).	Árvores de decisão, Regressão logística binária, SVM
P2, P3	Utilização de algoritmo próprio de limite de crédito, com resultado automatizado com base nas informações disponibilizada.	Árvores de decisão, Regressão logística binária, SVM

Fonte: Dados da pesquisa

3.6 Planejamento

Esta seção, bem como a de implementação, visam a aplicação de uma intervenção e buscam validar os resultados do modelo preditivo de *Data Analytics*. O presente estudo propõe uma abordagem para as ações em campo baseada em uma mescla dos tipos de dados apresentados na subseção 3.1, estabelecendo uma sequência de etapas. Convém salientar que a pesquisa intervencionista, também considerada dentro da vertente da pesquisa ação, é uma modalidade de experimento de campo, é mencionada como uma técnica que busca estudar o objeto em sua prática cotidiana (Westin & Roberts, 2010). Convém salientar que a abordagem se caracteriza pela mudança de atitude do pesquisador, por assumir um papel de interventor, deixando de somente analisar os dados e passa a agir sobre o objeto do estudo (Jonsson & Lucca, 2010).

Portanto, como fase 1 da coleta de dados é identificada a amostra na Tabela 11 que fará parte das etapas pré e pós-intervenção e para a fase 2 da coleta de dados a amostra referente aos gestores são identificados pelas regiões na Tabela 13.

3.6.1 Amostra considerada para as etapas pré e pós-intervenção.

A seleção da amostra foi realizada considerando a diversidade das unidades de negócio do grupo empresarial, distribuídas em regiões com diferentes dinâmicas econômicas e níveis de maturidade tecnológica. Para garantir representatividade, foram utilizados critérios como abrangência geográfica, priorizando estados com condições econômicas diversas, e a variabilidade nos indicadores financeiros analisados, como taxas de inadimplência e margens de lucro. Além disso, apenas unidades com dados financeiros consistentes e acessíveis foram incluídas, assegurando a confiabilidade das análises.

A pesquisa adotou duas abordagens de campo, já explicadas. A primeira abordagem, quase-experimental, dividiu as unidades em dois grupos estratificados: 41 unidades no grupo de pós-intervenção (que utilizaram ferramentas como Power BI, DataBricks e algoritmos de machine learning) com 73 colaboradores e 41 unidades com 72 colaboradores no grupo de pré-intervenção (que mantiveram os processos manuais tradicionais). A segunda abordagem, qualitativa, foi realizada por meio de entrevistas estruturadas com os colaboradores que passaram pela intervenção e outra por meio de um roteiro de entrevista com os 13 Gerentes Financeiros de cada região definida na amostra (Tabela 13).

No contexto desta pesquisa, o grupo pós-intervenção, recebeu treinamentos específicos e suporte para implementar as ferramentas de *Data Analytics*, enquanto o grupo pré-intervenção continuou com seus métodos de gestão tradicionais. Esta estratégia permite não só reconhecer a efetividade dos instrumentos de Análise de Dados, mas também medir o nível de maturidade na implementação dessas tecnologias na empresa. Na Tabela 11 pode-se ver a distribuição dos dados por estados, quantidade de estabelecimentos e quantidade de colaboradores.

Tabela 11

Distribuição unidades e colaboradores por estados brasileiros.

UF	QUANTIDADE DE UNIDADES	COLABORADORES
AL	2	4
AM	1	2
AP	1	2
BA	6	11
CE	3	5
DF	1	2

ES	3	5
GO	2	4
MA	2	4
MG	7	10
MS	2	4
MT	2	4
PA	3	5
PB	1	2
PE	3	5
PI	1	2
PR	5	9
RJ	5	9
RN	1	2
RO	1	2
RR	1	2
RS	5	9
SC	6	11
SE	1	2
SP	16	26
TO	1	2
Total	82	145

Fonte: Dados da Pesquisa

Para fins de confidencialidade dos dados, os nomes das empresas serão suprimidos. Para a intervenção proposta, o total de estabelecimentos foi dividido em dois, de forma que 1 metade sofreu a intervenção e a outra não, com o intuito de avaliar a possibilidade de impactos causados pela mesma ou se houve melhoria nos indicadores por outros fatores que não são objetos de estudo dessa pesquisa. Inicialmente a divisão será realizada por estado e quantidade de estabelecimentos superior a 2 a exemplo do Estado de Minas gerais constituído de 6 empresas. Neste caso 3 terão a intervenção implantada e 3 não.

Para os estados que possuem apenas 1 empresa, estes agrupados conforme a proximidade geográfica para uma melhor avaliação do fenômeno, conforme Blakely, E. J., & Reese, L. A. (2014) que analisou a relação entre o crescimento econômico e a proximidade espacial entre estados nos Estados Unidos. Os resultados indicaram que a proximidade geográfica desempenha um papel significativo no crescimento econômico, sugerindo que estados vizinhos tendem a ter um desempenho econômico semelhante. Dessa forma, os estabelecimentos foram agrupados (Tabela 12), conforme a distribuição geográfica estabelecida pelo IBGE (2017).

Tabela 12*Distribuição das empresas e unidades por estados brasileiros e agrupamento por região geográfica.*

UF	QUANTIDADE DE UNIDADES	REGIÃO
DF	1	Centro-Oeste
MS	2	Centro-Oeste
MT	2	Centro-Oeste
TO	1	Centro-Oeste
AL	2	Nordeste (outros)
MA	2	Nordeste (outros)
PB	1	Nordeste (outros)
PI	1	Nordeste (outros)
RN	1	Nordeste (outros)
SE	1	Nordeste (outros)
AM	1	Norte
AP	1	Norte
PA	3	Norte
RO	1	Norte
RR	1	Norte

Fonte: Dados da Pesquisa

O estado do Espírito Santo é o único estado da região sudeste que não tem mais de 1 empresa em si, e para fins de nosso estudo será agrupado com o estado do Rio de Janeiro. As empresas foram escolhidas de modo randômico para a eliminação de qualquer viés.

Por fim, após agrupamento dos estados e seleção dos estabelecimentos, a distribuição por estado bem como a distribuição de seus colaboradores é apresentada abaixo.

Tabela 13*Distribuição de unidades e colaboradores pós e pré intervenção*

Agrupamento	Unidades			Colaboradores		
	Pós	Pré	Total	Pós	Pré	Total
São Paulo	8	8	16	13	13	26
Rio de Janeiro + Espírito Santo	4	4	8	7	7	14
Nordeste (outros)	4	4	8	7	9	16
Norte	3	4	7	6	7	13
Minas Gerais	4	3	7	5	5	10
Santa Catarina	3	3	6	6	5	11
Centro-Oeste	3	3	6	6	6	12
Bahia	3	3	6	6	5	11

Rio Grande do Sul	2	3	5	4	5	9
Paraná	2	3	5	5	4	9
Pernambuco	2	1	3	3	2	5
Ceará	2	1	3	3	2	5
Goiás	1	1	2	2	2	4

Fonte: Dados da Pesquisa

3.6.2. Métricas a serem comparados nas etapas pré e pós intervenção

Os indicadores financeiros são ferramentas essenciais para a análise e o monitoramento da saúde financeira de uma empresa e medida de eficiência de sua gestão.

O Prazo Médio de Recebimento (PMR) é um indicador que mede o tempo médio necessário para que uma empresa receba o pagamento de suas vendas. Ele é calculado dividindo-se o valor médio das contas a receber pelo faturamento diário médio da empresa.

A inadimplência representa a parcela de clientes ou devedores que não honram seus compromissos financeiros dentro do prazo estabelecido. Calculada como a razão entre o valor total em atraso e o valor total das vendas a prazo ou da carteira de crédito, a inadimplência serve como um termômetro da saúde financeira de uma empresa. Níveis elevados desse indicador sinalizam um risco elevado de crédito, impactando negativamente o fluxo de caixa e a lucratividade. Conforme destacado por Silva e Cavalcante (2018), a gestão eficaz da inadimplência exige a adoção de políticas robustas de concessão de crédito, cobrança e análise de risco. A tabela 14 apresenta os indicadores a serem comparados e o respectivo cálculo.

Tabela 14

Indicadores comparados

Métricas	Definição	Cálculo
Prazo Médio de Recebimento (PMR)	Tempo médio para receber o pagamento de vendas.	Valor médio das contas a receber / Faturamento diário médio
Inadimplência	Proporção de clientes que não honram seus compromissos.	Valor total em atraso / Valor total das vendas a prazo

Fonte: Silva e Cavalcanti (2018)

3.7 Implementação dos modelos de *Data Analytics*

3.7.1. Estimação do modelo – Risco de inadimplência

A base de dados utilizada foi extraída do sistema ERP da organização, e continha, entre outras informações, as seguintes variáveis principais:

- (i) Código do Cliente, que permite a individualização do histórico de crédito e comportamento de pagamento de cada comprador;
- (ii) Valor do Título (R\$), que representa o montante monetário da parcela emitida na venda;
- (iii) Dias em Atraso, variável contínua que expressa a quantidade de dias decorridos desde o vencimento da parcela sem quitação;
- (iv) Data do Último Pagamento, medida temporal relacionada ao comportamento recente do cliente;
- (v) Indicador de Inadimplência, variável binária que informa se o cliente estava inadimplente no momento da extração dos dados e
- (vi) Código do Vendedor, uma variável categórica que representa o profissional responsável pela negociação, podendo também influenciar a performance do crédito.

A árvore de decisão foi aplicada inicialmente por sua capacidade de gerar regras explícitas e compreensíveis. Essa técnica constrói um modelo hierárquico onde as decisões são tomadas com base em divisões sucessivas dos dados, em função dos valores das variáveis explicativas. A partir disso, foi possível visualizar segmentos de clientes com alta recorrência de atraso, histórico recente de inadimplência e elevado valor de título como sendo mais propensos a risco elevado. O modelo gerado evidenciou, por exemplo, que clientes com mais de 45 dias de atraso e que não realizaram pagamentos nos últimos três meses possuíam alta probabilidade de inadimplência, sobretudo quando o valor em aberto ultrapassava determinado limiar. Essa transparência nas regras de classificação contribuiu para a interpretação gerencial e posterior formulação de estratégias de cobrança diferenciadas.

A seguir, utilizou-se a regressão logística binária, que embora tenha como objetivo principal a previsão de desfechos binários (inadimplente ou não), foi útil para gerar probabilidades de inadimplência, que posteriormente foram reagrupadas em faixas para fins de classificação em três níveis. A regressão logística modelou a chance de um cliente estar inadimplente com base em uma combinação linear das variáveis explicativas transformadas pela função logística. O modelo gerado permitiu identificar relações estatisticamente significativas entre as variáveis preditoras e a inadimplência. Notadamente, os coeficientes obtidos mostraram que o número de dias em atraso e o histórico de pagamentos anteriores foram as variáveis mais relevantes, com significância estatística elevada ($p < 0,01$). A principal vantagem da regressão logística é a facilidade de interpretação dos efeitos marginais de cada variável na probabilidade de inadimplência.

Por fim, aplicou-se o modelo de aprendizado de máquina Máquinas de Vetores de Suporte (SVM), que se destaca em cenários onde os dados não são linearmente separáveis e requerem uma técnica mais robusta para encontrar fronteiras ótimas de separação entre classes. A SVM construiu hiperplanos que dividiram o espaço de variáveis com base em margens máximas entre os pontos classificados como adimplentes e inadimplentes. A principal contribuição da SVM foi aprimorar a acurácia da classificação para os casos intermediários — clientes com risco médio — que não eram bem capturados pelas outras técnicas. O kernel radial (RBF) foi utilizado para capturar relações não lineares entre as variáveis, o que aumentou a capacidade preditiva geral do modelo. O uso combinado dos três algoritmos foi, portanto, estratégico: enquanto a árvore fornece interpretabilidade, a regressão logística traz robustez estatística e a SVM maximiza a precisão nas zonas cinzentas do modelo.

Para operacionalizar a classificação do risco em três níveis (Tabela 15), foram definidos critérios baseados nas probabilidades estimadas pelos modelos e reforçados pelas regras extraídas da árvore de decisão. Clientes com probabilidade inferior a 30% de inadimplência foram classificados como baixo risco. Aqueles com probabilidade entre 30% e 60% foram rotulados como médio risco, enquanto clientes com probabilidade superior a 60%, especialmente os que combinavam atraso superior a 45 dias, ausência de pagamento recente e valor em aberto elevado, foram considerados alto risco. Essa categorização foi validada por meio de análise de sensibilidade e matriz de confusão, indicando acurácia superior a 85% na identificação correta dos casos extremos (baixo e alto risco), embora, como esperado, o risco médio mantivesse maior incerteza associada.

Adicionalmente, os dados foram segmentados por código do vendedor, permitindo identificar se havia correlação entre determinadas equipes comerciais e o nível de risco atribuído aos clientes sob sua responsabilidade. A análise revelou clusters de vendedores com maior concentração de clientes de alto risco, o que gerou dados para a revisão de políticas comerciais, treinamentos direcionados e avaliação do processo de concessão de crédito.

Tabela 15

Classificação de riscos do algoritmo

Faixa de Probabilidade (p)	Classificação de Risco	Critério Combinado Utilizado
----------------------------	------------------------	------------------------------

$p \leq 0,30$	Baixo	Probabilidade baixa na regressão; suporte da árvore e confirmação por SVM
$0,30 < p \leq 0,60$	Médio	Probabilidade intermediária; SVM foi decisiva para refinar a separação
$p > 0,60$	Alto	Alta chance de inadimplência; identificado com clareza pelas três técnicas

Fonte: Dados da Pesquisa

Inicialmente os dados avaliados apresentavam a seguinte configuração definida na Tabela 16.

Tabela 16

10 primeiras ocorrências da base de dados estudada

Cod. Cliente	Valor Título (R\$)	Dias em Atraso	Data Último Pagamento	Inadimplente?	Qtd. Atrasos	Vendedor
413	2.450	15	15/02/2025	Não	2	151030
6200	5.780	45	10/01/2025	Sim	5	151027
6348	1.230	0	10/03/2025	Não	0	151019
3489	8.990	60	20/12/2024	Sim	7	151016
4278	3.120	30	05/02/2025	Sim	3	151023
3551	6.700	10	28/02/2025	Não	1	151020
4164	4.500	90	15/11/2024	Sim	9	151019
695	1.800	5	05/03/2025	Não	0	151024
989	9.300	120	01/10/2024	Sim	12	151020
5147	2.100	0	20/03/2025	Não	0	151012

Fonte: Relatório de contas a receber do extraído do ERP

Os dados referentes à tabela 15 são:

- Cod. Cliente = Identificação numérica do cliente no ERP.
- Valor Título (R\$) = Valor da parcela registrada no momento da venda
- Dias em atraso = Dias em atraso do cliente tem atrasado naquele título em específico;
- Data último pagamento = Quantidade de títulos liquidados em atraso por cliente nos últimos 12 meses;

- Inadimplente: Se o cliente estava inadimplente no momento da extração dos dados
- Vendedor = Código do vendedor cadastrado no ERP;

Sendo o objeto de análise a probabilidade de ocorrência do evento inadimplência variando de 0 para não ocorrência e 1 para ocorrência do evento com base nas suas variáveis preditoras, o modelo que melhor se adequa ao evento estudado é a modelo de regressão de logística binária.

Na maioria das vezes, os modelos de regressão estabelecem a relação entre uma variável resposta e uma ou mais variáveis independentes (explanatórias). No caso da Regressão Logística, a variável resposta é discreta, podendo, dessa forma, ser utilizada para descrever a relação entre a ocorrência ou não de um evento de interesse e um conjunto de variáveis explanatórias.

3.7.2. Estimação do modelo – Classificação de riscos de contas a receber

Para estimar o modelo, separamos a base de treino e a base de teste. Desta forma, selecionamos 70% da base em relação a quantidade de ocorrências de forma aleatória para executar os nossos procedimentos de estimação de modelo e 30% de nossa base para testar a eficiência do modelo proposto. Os scripts utilizados em *python* para cada técnica de aprendizado de máquina seguem relacionados.

3.7.2.1. Árvore de decisão

```
# Treinar Árvore de Decisão
tree = DecisionTreeClassifier(max_depth=3)
tree.fit(X_train, y_train)
# Previsões e avaliação
y_pred_tree = tree.predict(X_test)
print("\n--- Árvore de Decisão ---")
print("Acurácia:", accuracy_score(y_test, y_pred_tree))
print(classification_report(y_test, y_pred_tree))
```

Após executar o script o obtivemos o seguinte output:

```
text

--- Árvore de Decisão ---
Acurácia: 0.93
              precision    recall  f1-score   support
0             0.95         0.92         0.93         24
1             0.91         0.95         0.93         21
 accuracy                   0.93         45
 macro avg                  0.93         45
 weighted avg               0.93         45
```

Figura 7. Output do modelo proposto

3.7.2.2. Regressão Logística Binária

```
# Treinar Regressão Logística
logreg = LogisticRegression()
logreg.fit(X_train, y_train)
# Previsões e avaliação
```

```

y_pred_logreg = logreg.predict(X_test)
print("\n--- Regressão Logística ---")
print("Acurácia:", accuracy_score(y_test, y_pred_logreg))
print(classification_report(y_test, y_pred_logreg))

```

Após executar o script o obtivemos o seguinte output:

```

--- Regressão Logística ---
Acurácia: 0.89

```

	precision	recall	f1-score	support
0	0.90	0.88	0.89	24
1	0.87	0.90	0.88	21
accuracy			0.89	45
macro avg	0.89	0.89	0.89	45
weighted avg	0.89	0.89	0.89	45

Figura 8. Output do modelo proposto

3.7.2.3. SVM (Support Vector Machine)

```

# Treinar Regressão Logística
svm = SVC(kernel='linear')
svm.fit(X_train, y_train)
# Previsões e avaliação
y_pred_svm = svm.predict(X_test)
print("\n--- SVM ---")
print("Acurácia:", accuracy_score(y_test, y_pred_svm))
print(classification_report(y_test, y_pred_svm))

```

Após executar o script o obtivemos o seguinte output:

```

--- SVM ---
Acurácia: 0.91

```

	precision	recall	f1-score	support
0	0.92	0.92	0.92	24
1	0.90	0.90	0.90	21
accuracy			0.91	45
macro avg	0.91	0.91	0.91	45
weighted avg	0.91	0.91	0.91	45

Figura 9. Output do modelo proposto

3.7.3 Métricas utilizadas na avaliação dos modelos

A avaliação de modelos de classificação binária, como os aplicados na previsão de inadimplência, requer a utilização de métricas específicas que capturem diferentes aspectos do desempenho preditivo. Neste contexto, três métricas principais são comumente empregadas: acurácia, precisão e revocação (também conhecida como *recall* ou sensibilidade). Cada uma dessas métricas oferece insights distintos sobre a eficácia do modelo, sendo essencial compreender suas definições, aplicações e limitações para uma interpretação adequada dos resultados.

A acurácia representa a proporção total de previsões corretas em relação ao conjunto de dados, abrangendo tanto os verdadeiros positivos (VP) quanto os verdadeiros negativos (VN). Embora seja uma métrica intuitiva e de fácil interpretação, sua utilidade é limitada em cenários com

classes desbalanceadas. Por exemplo, em um contexto em que a maioria dos clientes é adimplente, uma alta acurácia pode simplesmente refletir a predominância da classe majoritária, mascarando a incapacidade do modelo de identificar corretamente os casos de inadimplência.

A precisão, por sua vez, mede a confiabilidade das previsões positivas do modelo, calculando a proporção de verdadeiros positivos (VP) em relação a todas as previsões classificadas como positivas (VP + FP). Uma alta precisão indica que, quando o modelo classifica um cliente como inadimplente, há uma elevada probabilidade de essa classificação estar correta. Essa métrica é particularmente relevante quando os falsos positivos (FP) acarretam custos significativos, como no caso de ações de cobrança direcionadas a clientes que, na realidade, estão em dia com seus pagamentos.

Por fim, a revocação avalia a capacidade do modelo de identificar corretamente os casos positivos reais, sendo calculada como a proporção de verdadeiros positivos (VP) em relação ao total de positivos reais (VP + FN). Um alto valor de revocação indica que o modelo é eficaz em detectar a maioria dos clientes inadimplentes, minimizando os falsos negativos (FN). Essa métrica é crucial em contextos em que a falha em identificar um caso positivo (como um cliente inadimplente) pode gerar prejuízos financeiros ou operacionais. Na Tabela 17, são apresentadas as métricas de cada técnica utilizada.

Tabela 17

Resumo estatístico de cada técnica

Técnica	Acurácia	Precision (Inadimplente)	Recall (Inadimplente)
Árvore de Decisão	93%	91%	95%
Regressão Logística	89%	87%	90%
SVM	91%	90%	90%

Fonte: Dados extraídos do ERP e processados via DataBricks

3.7.4 Painel desenvolvido no Power BI

A construção do painel desenvolvido no Power BI (Figura 10) representa uma etapa essencial na consolidação visual e analítica dos dados utilizados nesta pesquisa. Por meio de sua interface interativa, clara e dinâmica, foi possível organizar, filtrar e exibir as informações mais relevantes relacionadas à inadimplência de clientes, com o objetivo de apoiar a tomada de decisão no âmbito da controladoria e da gestão de crédito.

A apresentação visual dos dados foi projetada para facilitar o entendimento e a análise rápida por parte dos gestores financeiros, oferecendo uma visão consolidada dos principais indicadores associados ao comportamento de pagamento dos clientes. A ferramenta proporciona filtros interativos, como a classificação de risco de inadimplência, posicionada no canto superior esquerdo, que permite a segmentação imediata dos dados conforme o grau de risco (alto, médio ou baixo). Essa funcionalidade garante uma análise mais direcionada e eficiente, permitindo ao usuário priorizar ações de cobrança com base na criticidade dos casos.

O painel apresenta colunas organizadas com os seguintes campos: Nome do Cliente, Valor do Título em Aberto, Parcela, Quantidade de Dias em Atraso, Data de Vencimento do Boleto Mais Antigo, Data do Último Pagamento, Telefone de Contato, e o Código do Vendedor. Cada cliente é automaticamente classificado por risco com a utilização de indicadores visuais que tornam a leitura mais intuitiva: ícones circulares vermelhos para alto risco, amarelos para médio risco e verdes para baixo risco.

A classificação segue a lógica estatística construída ao longo do modelo analítico, com base na probabilidade de inadimplência calculada pelas técnicas de machine learning aplicadas (Árvore de Decisão, Regressão Logística Binária e SVM), como detalhado anteriormente neste trabalho. A

ordenação dos dados foi estruturada para que os registros de maior risco apareçam no topo da visualização, garantindo foco imediato nas situações mais críticas.

Quanto às técnicas de análise, o aprendizado de máquina e a mineração de dados são métodos avançados que permitem identificar padrões e prever comportamentos, como a inadimplência de clientes. Segundo Hastie, Tibshirani e Friedman (2017), essas técnicas estatísticas estimam a relação entre variáveis dependentes e independentes, permitindo a identificação dos fatores que influenciam a probabilidade de inadimplência e a quantificação de seu impacto.

No contexto da previsão de inadimplência, o modelo de regressão logística é uma técnica estatística amplamente utilizada. Segundo Hastie, Tibshirani e Friedman (2017), a regressão logística estima a relação entre uma variável dependente binária e uma ou mais variáveis independentes. No caso da previsão de inadimplência, o modelo de regressão logística pode ser utilizado para identificar os fatores que influenciam a probabilidade de inadimplência e quantificar seu impacto. Essa técnica permite que as empresas identifiquem os clientes com maior risco de inadimplência e adotem medidas preventivas para mitigar esse risco.

Além da regressão logística, outras técnicas de análise, como árvores de decisão e redes neurais, também são utilizadas na previsão de inadimplência.

EMPRESA ALFA									
CLASSIFICAÇÃO DE RISCO									
Alto									
CLIENTE	VALOR DO TÍTULO EM ABERTO	PARCELA	RISCO	DIAS EM ATRASO	VENCIMENTO DO BOLETO MAIS ANTIGO	TELEFONE	DATA DO ÚLTIMO PAGAMENTO	CÓDIGO DO VENDEDOR	
Cliente A	R\$ 10.800	4	Alto	23	31/03/2025	19 9xxx-xxxx	13/02/2025	151021	
Cliente B	R\$ 7.200	2	Alto	20	28/03/2025	19 9xxx-xxxx	07/02/2025	151005	
Cliente C	R\$ 15.500	3	Risco	17	25/03/2025	19 9xxx-xxxx	06/02/2025	151014	
Cliente D	R\$ 5.400	4	Médio	15	24/03/2025	15 9xxx-xxxx	31/02/2025	151025	
Cliente E	R\$ 12.800	5	Baixo	12	23/03/2025	14 9xxx-xxxx	15/02/2025	151010	
Cliente F	R\$ 7.800	6	Baixo	10	22/03/2025	13 9xxx-xxxx	16/02/2025	151018	
Cliente G	R\$ 13.500	8	Low	8	21/03/2025	13 2xxx-xxxx	13/03/2025	151034	
Cliente H	R\$ 5.100	6	Baixo	6	20/03/2025	13 2xxx-xxxx	31/03/2025	151022	
Cliente I	R\$ 10.300	3	Baixo	4	19/03/2025	12 8xxx-xxxx	13/02/2025	151019	
Cliente J	R\$ 3.300	1	Baixo	2	31/03/2025	12 9xxx-xxxx	15/02/2025	151028	

Figura 10 Painel de Power BI com classificação de risco

3.7.5. Estimação do modelo – Limite de crédito

A determinação do limite de crédito é um processo estratégico que combina dados históricos, indicadores financeiros e variáveis comportamentais para minimizar riscos e maximizar a concessão adequada.

Tabela 18

10 primeiros clientes do cadastro de contas a receber

Cod. Cliente	Dias em Atraso	Inadimplente?	Qtd. Atrasos	Score Serasa	Capital Social (R\$)	Regime Tributação	Segmento	Pagamentos (R\$)
--------------	----------------	---------------	--------------	--------------	----------------------	-------------------	----------	------------------

58140	0	Não	0	780	150.000,00	Simples	Auto	25.000,00
42256	45	Sim	5	350	80.000,00	MEI	Moto	12.500,00
45893	0	Não	1	850	1.200.000,00	Real	C.Bateria	95.000,00
25394	60	Sim	8	290	45.000,00	Simples	Oficina	8.000,00
91770	15	Não	2	680	300.000,00	MEI	Auto	18.000,00
44568	90	Sim	12	200	25.000,00	MEI	Moto	5.000,00
51367	0	Não	0	920	1.500.000,00	Lucro	C.Bateria	120.000,00
77293	30	Sim	4	420	60.000,00	Simples	Oficina	10.000,00
82205	0	Não	0	750	500.000,00	Real	Moto	50.000,00
4010	120	Sim	10	180	30.000,00	MEI	Moto	3.000,00

Fonte: Extraído do ERP via banco de dados com a ferramenta *DataBricks*

A Tabela 18 apresenta a posição do limite de crédito, com as seguintes informações:

Cod. Cliente = Identificação numérica do cliente no ERP.

Dias_atraso = Dias em atraso do cliente tem atrasado naquele título em específico;

Inadimplente: Se o cliente estava inadimplente no momento da extração dos dados

Qtd. Atrasos = Quantidade de atrasos em 12 meses

Score Serasa = Score capturado no Serasa via API

Capital Social – Valor do capital social capturado no momento do cadastro no contrato social

Regime de tributação = MEI, Simples Nacional, Lucro Presumido e Lucro Real

Segmento = Segmento do mercado de acordo com cadastro interno podendo ser: Auto peças, Moto peças, Casa de Bateria, Oficina e outros;

Média de Pagamentos = Valor de pagamento nos últimos 12 meses.

Nesta análise, foram selecionadas variáveis-chave relevantes na literatura de crédito e risco, como Score Serasa (indicador direto de risco de inadimplência), Capital Social (reflete a capacidade patrimonial do cliente), Dias em Atraso e Quantidade de Atrasos (medem a recorrência de comportamentos de risco), além da Média de Pagamentos (indica fluxo financeiro regular). Essas variáveis foram escolhidas por sua capacidade preditiva em modelos de *machine learning*, como Árvores de Decisão e Regressão Logística, e por representarem dimensões críticas da saúde financeira do cliente: solvência (Score e Capital Social), histórico de pagamentos (Atrasos) e capacidade de geração de renda (Média de Pagamentos). A segmentação por Regime Tributário e Segmento de Mercado adiciona camadas contextuais, permitindo ajustes setoriais às políticas de crédito. A seguir, detalha-se como cada modelo utiliza essas variáveis para calcular limites personalizados, equilibrando risco e oportunidade.

A utilização da média ponderada dos limites de crédito sugeridos pelas três técnicas (Árvore de Decisão, Regressão Logística e SVM) visa equilibrar as vantagens e limitações de cada modelo, garantindo uma decisão mais robusta e menos enviesada. Enquanto a Árvore de Decisão oferece interpretabilidade e captura relações não lineares (como interações entre Score Serasa e Qtd. Atrasos), a Regressão Logística fornece uma base estatística sólida para probabilidades de inadimplência, e o SVM identifica padrões complexos em dados de alta dimensionalidade. Ao agregar os resultados, mitigamos o risco de supervalorizar um único critério — como o Score Serasa (priorizado pela Regressão Logística) ou a margem do hiperplano (SVM) — e incorporamos uma visão holística do perfil do cliente. Essa abordagem híbrida é respaldada pela literatura (Lessmann et al., 2015) e alinha-se a práticas de mercado que combinam modelos para reduzir falsos positivos/negativos, assegurando que o limite concedido reflita tanto a capacidade de pagamento (dados financeiros) quanto o comportamento histórico (atrasos e inadimplências).

Os scripts utilizados em *python* para cada técnica de aprendizado de máquina seguem relacionados.

3.7.5.1 *Árvore de Decisão*

Limite de Crédito Sugerido:

Clientes com probabilidade < 0.3 : Limite Alto (até 80% do capital social).

Clientes com probabilidade ≥ 0.3 : Limite Reduzido (até 30% do capital social).

```
# Treinar Árvore de Decisão
from sklearn.tree import DecisionTreeClassifier
from sklearn.metrics import classification_report
# Previsões e avaliação
tree = DecisionTreeClassifier(max_depth)
tree.fit(X_train, y_train)
y_pred_tree = tree.predict(X_test)
print("\n--- Árvore de Decisão ---")
print(classification_report(y_test, y_pred_tree))
```

Após executar o script o obtivemos o seguinte output:

	precision	recall	f1-score	support
0	0.92	0.95	0.93	56
1	0.90	0.85	0.87	34
accuracy			0.91	90

Figura 11. Output do modelo proposto

3.7.5.2 *Regressão Logística Binária*

Critério:

Probabilidade de inadimplência (threshold = 0.5).

Limite de Crédito Sugerido:

Score Serasa > 700 : Limite de 100% do capital social.

Score Serasa 500-700: Limite de 50% do capital social.

Score Serasa < 500 : Limite de 10% do capital social.

```
# Treinar Regressão logística Binária
from sklearn.linear_model import LogisticRegression
logreg = LogisticRegression
logreg.fit(X_train, y_train)
# Previsões e avaliação
y_pred_logreg = logreg.predict(X_test)
print("\n--- Regressão Logística ---")
print(classification_report(y_test, y_pred_logreg))
```

Após executar o script o obtivemos o seguinte output:

	precision	recall	f1-score	support
0	0.89	0.93	0.91	56
1	0.87	0.79	0.83	34
accuracy			0.88	90

Figura 12. Output do modelo proposto

3.7.5.3 SVM (Support Vector Machine)

Critério:

Kernel linear para classificação binária.

Limite de Crédito Sugerido:

Margem do Hiperplano > 1.5: Limite total.

Margem entre 0.5 e 1.5: Limite parcial.

Margem < 0.5: Sem crédito.

Treinar SVM

```
from sklearn.svm import SVC
```

```
svm = SVC(kernel='linear', probability=True)
```

```
svm.fit(X_train, y_train)
```

Previsões e avaliação

```
y_pred_svm = svm.predict(X_test)
```

```
print("\n--- SVM ---")
```

```
print(classification_report(y_test, y_pred_svm))
```

Após executar o script o obtivemos o seguinte output:

```

text
      precision    recall  f1-score   support
0         0.91      0.93      0.92         56
1         0.87      0.82      0.85         34
accuracy                0.89         90
  
```

Figura 13. Output do modelo proposto

Após aplicar as 3 técnicas de aprendizado de máquina, o limite sugerido para os 5 primeiros clientes está contido na tabela 19.

Tabela 19

Limite de crédito estabelecido pelas técnicas de aprendizado de máquina

Cod. Cliente	Árvore	Reg. Log	SVM	Média
58140	120.000,00	150.000,00	150.000,00	140.000,00
42256	24.000,00	8.000,00	-	10.666,67
45893	960.000,00	1.200.000,00	1.200.000,00	1.120.000,00
25394	13.500,00	45.000,00	-	19.500,00
91770	90.000,00	150.000,00	90.000,00	110.000,00

Fonte: Dados da pesquisa

Os padrões identificados durante a análise revelam um consenso entre os modelos no que se refere aos clientes com scores altos (acima de 700), para os quais todas as técnicas indicam limites de crédito mais elevados, demonstrando uma uniformidade nas decisões de concessão. No entanto, observa-se uma divergência significativa no tratamento de clientes com scores médios ou baixos. O modelo baseado em árvore de decisão apresenta maior tolerância a variáveis contextuais, sendo mais flexível e propenso a aprovar limites mesmo em situações de score reduzido, desde que outras variáveis de apoio (como histórico de pagamento recente ou valor baixo de título) sejam favoráveis. Por outro lado, o modelo SVM se mostrou mais conservador, rejeitando automaticamente clientes com score inferior a 300, independentemente de outros fatores, o que evidencia uma rigidez maior na separação entre perfis de risco. Já a regressão logística binária posiciona-se de forma

intermediária entre os dois extremos, com decisões mais equilibradas, embora com forte influência do score Serasa como variável explicativa predominante, o que a torna mais sensível a essa métrica na definição do risco. Na Tabela 20 abaixo, apresenta a comparação os limites para os 5 primeiros clientes da base.

Tabela 20

Comparação de limites estabelecidos pelas técnicas de aprendizado de máquina

Cod. Cliente	Limites disponibilizados	Comportamento dos Modelos
58140	- Árvore: R\$ 120.000 - Logística/SVM: R\$ 150.000	Diferença ocorre porque a Árvore penaliza variáveis não lineares (ex.: alto valor de título em aberto), enquanto Logística/SVM confiam mais no Score alto.
42256	- Árvore: R\$ 24.000 - Logística: R\$ 8.000 - SVM: R\$ 0	Score baixo indica alto risco. A Árvore é mais flexível, enquanto SVM é conservador (rejeita crédito).
45893	Todos sugerem limites acima de R\$ 900.000	Score altíssimo e histórico impecável levam a consenso entre modelos.
25394	- Árvore: R\$ 13.500 - Logística: R\$ 4.500 - SVM: R\$ 0	Score muito baixo + atrasos frequentes. SVM é o mais restritivo.
91770	- Árvore/SVM: R\$ 90.000 - Logística: R\$ 150.000	Logística é mais otimista com Scores médios-altos, enquanto Árvore/SVM consideram outros riscos (ex.: capital social baixo).

Fonte: Dados da Pesquisa

O painel de limite está disponível em Power Bi para os analistas de crédito conforme figura 14.



Empresa Alfa

Cliente

(Selecionar tudo) ▾

Cliente	Média Compras (12M)	PMR (dias)	PMV (dias)	Limite de Crédito Sugerido
Cliente A	R\$ 32.145,00	85	90	R\$ 40.000,00
Cliente B	R\$ 5.890,00	78	60	R\$ 6.500,00
Cliente C	R\$ 41.200,00	90	120	R\$ 42.000,00
Cliente D	R\$ 10.300,00	76	30	R\$ 12.000,00

Figura 14. Painel de Power BI com limites estabelecidos

3.7.6. Treinamento no uso das ferramentas

O treinamento foi conduzido de forma remota, via Microsoft Teams, com três turmas distintas, sendo duas delas compostas por 25 participantes cada e a terceira por 23 participantes,

totalizando 73 indivíduos. A carga horária foi de 4 horas, divididas em dois dias, com sessões de 2 horas diárias. O objetivo central foi capacitar os participantes na utilização de uma ferramenta de *data analytics* aplicada a crédito e cobrança, abordando desde conceitos fundamentais até a prática operacional.

No primeiro dia, o treinamento se concentrou na introdução à análise de dados para gestão de crédito, destacando métricas essenciais como Perda por Inadimplência (PDD), Perda Dada a Inadimplência e taxas de inadimplência, além da exploração de fontes de dados e sistemas internos. Em seguida, foi realizada uma demonstração prática da ferramenta, com ênfase na importação de dados e na visualização de *dashboards*. Por fim, foi apresentada a ferramenta de cobrança passo a passo, com um estudo de caso simulando a análise de uma carteira de cobrança, incluindo técnicas como *clustering* de devedores para segmentação de risco. Ao final, houve uma discussão guiada sobre como a ferramenta poderia auxiliar na redução da inadimplência e otimizar decisões.

No segundo dia do treinamento, o foco foi direcionado para dois pilares essenciais na gestão de crédito: o conceito de score de crédito e a implementação prática de uma ferramenta de limite de crédito utilizando o Power BI. A sessão, com duração de 2 horas, foi estruturada para proporcionar uma compreensão teórica sólida, seguida de uma aplicação prática, permitindo aos participantes visualizar como esses conceitos podem ser operacionalizados no dia a dia das organizações.

A segunda parte da sessão concentrou-se na construção de uma ferramenta automatizada para cálculo de limites de crédito, integrando o score de crédito a outras variáveis relevantes, como renda, patrimônio e histórico de relacionamento. A implementação foi realizada no Power BI, permitindo a visualização interativa e a simulação de cenários.

4. RESULTADOS

Após 12 meses da implementação, este estudo avaliou de forma abrangente os efeitos da implementação de ferramentas de *Data Analytics* nos processos financeiros do conglomerado Alfa, composto por 54 empresas distribuídas em 82 unidades localizadas em 25 estados brasileiros. A pesquisa adotou duas abordagens de campo, já explicadas.

4.1 Apresentação e análise dos dados quantitativos

O estudo abrangeu um volume de dados relativos a um total de 39.423 clientes dos distribuidores da empresa Alfa, sendo 19.862 clientes (50,4%) incluídos no grupo de pós-intervenção, que utilizou ferramentas de *Data Analytics* para gestão de crédito e cobrança, enquanto os 19.561 clientes restantes (49,6%) compuseram o grupo pré-intervenção, mantendo os processos tradicionais. O período analisado compreendeu março de 2024 a março de 2025, abrangendo um ciclo completo de operações e permitindo a comparação direta dos resultados antes e após a implementação das soluções tecnológicas.

De acordo com a sugestão de segmentação geográfica foram estabelecidas 13 grupos para avaliação e comparação de resultados. Os dados foram estratificados por região, porte do cliente e histórico de pagamento, garantindo uma análise equilibrada entre os grupos. No grupo de intervenção, os clientes foram monitorados por meio de algoritmos preditivos que classificaram o risco de inadimplência em tempo real, enquanto o Grupo pré intervenção seguiu com avaliações manuais baseadas em planilhas e relatórios estáticos. Os dados foram coletados diretamente dos sistemas ERP da empresa, com extrações diárias de indicadores como prazo médio de recebimento (PMR), taxa de inadimplência, despesas operacionais por unidade e resultado financeiro líquido.

4.1.1. Análise de PMR Antes da Implementação

Os dados foram estratificados por região, calculando-se medidas descritivas (média, desvio padrão, mínimo e máximo) para o PMR. A análise comparativa buscou identificar clusters de desempenho e correlacioná-los com possíveis variáveis contextuais, como investimentos em infraestrutura e políticas de manutenção regionalizadas.

Tabela 21*Análise de dados PMR antes de implementação*

Região	Qtd Clientes	Desvio Padrão	PMR Médio (dias)
Ceará	829	2,56	74,95
Nordeste (outros)	1299	2,6	74,96
Bahia	1642	5,69	80,20
Centro-Oeste	1008	2,59	84,78
Goiás	817	2,58	84,97
Rio Grande do Sul	779	2,59	84,97
Norte	1362	2,58	85,03
Paraná	1631	10,28	85,08
Minas Gerais	2517	5,38	88,41
São Paulo	4010	8,42	88,95
Rio de Janeiro e Espírito Santo	1591	5,57	89,86
Santa Catarina	1600	5,57	89,96
Pernambuco	777	2,61	95,13

Fonte: Dados extraídos do ERP e processados via *Databricks*

O PMR médio geral é de 85,94, com uma variação significativa entre 74,95 (mínimo) e 95,13 (máximo). O desvio padrão global de 7,81 indica uma dispersão considerável, sugerindo que algumas regiões têm desempenhos muito acima ou abaixo da média nacional.

A análise dos dados revela padrões distintos no desempenho da manutenção entre as regiões brasileiras. Observa-se que:

- As regiões Sul e Sudeste concentram os maiores valores médios de PMR, com destaque para Santa Catarina (89,96) e Rio de Janeiro/ES (89,86)
- As regiões Nordeste (outros) e Norte apresentam os menores índices médios, sendo Ceará (74,95) e Nordeste (outros) (74,96) os casos mais relevantes
- A variabilidade dos dados mostra comportamento diferenciado:
 - Regiões como Centro-Oeste, Nordeste e Norte mantêm baixa dispersão (DP ~2,6)
 - Paraná (DP=10,28) e São Paulo (DP=8,42) apresentam a maior variabilidade
 - Quanto à distribuição amostral:
 - São Paulo responde por 20% do total de observações (4.010 registros)
 - Sete regiões possuem entre 1.000-2.000 observações
 - Cinco regiões apresentam menos de 1.000 registros

Chama atenção a amplitude significativa em algumas regiões, como Paraná (variação de 28 pontos) em contraste com a estabilidade de outras como Pernambuco (variação de apenas 8 pontos).

4.1.2. Análise da Inadimplência Antes da Implementação

Os dados foram estratificados por localidade, calculando-se indicadores descritivos (taxa média de inadimplência, desvio padrão, valores mínimo e máximo) para avaliar o comportamento do atraso no pagamento. Os índices de inadimplência foram regionalizados e submetidos a análise estatística descritiva (média, dispersão e extremos).

Tabela 22

Análise de dados de Inadimplência antes de implementação

Região	Qtd Clientes	Desvio Padrão	Inadimplência Média
Bahia	1642	0,57	1,99
Nordeste (outros)	1299	0,87	2,47
Centro-Oeste	1008	0,88	2,49
Norte	1362	0,85	2,49
Pernambuco	777	0,3	2,5
Santa Catarina	1600	0,59	3,01
Minas Gerais	2517	0,87	3,49
Paraná	1631	1,03	3,5
Ceará	829	0,29	3,51
Rio de Janeiro e Espírito Santo	1591	1,03	3,52
São Paulo	4010	0,85	3,88
Goiás	817	0,28	4,50
Rio Grande do Sul	779	0,29	4,51

Fonte: Dados extraídos do ERP e processados via *Databricks*

Os dados revelam uma distribuição heterogênea dos índices de inadimplência entre as diferentes regiões brasileiras. As regiões Nordeste (outros) e Norte apresentam os menores índices médios, com Bahia (1,99%), Nordeste (outros) (2,47%) e Norte (2,49%) formando um grupo com desempenho similar. Pernambuco (2,50%) e Centro-Oeste (2,49%) apresentam valores próximos, completando este conjunto de regiões com melhor desempenho.

Em contrapartida, as regiões Sul e Sudeste concentram os maiores índices médios de inadimplência. Goiás (4,50%) e Rio Grande do Sul (4,51%) destacam-se com os valores mais elevados, seguidos por São Paulo (3,88%). Minas Gerais (3,49%), Paraná (3,50%) e Rio de Janeiro/ES (3,52%) formam um grupo intermediário, porém com índices significativamente superiores às regiões de melhor desempenho.

4.1.2.1. Variabilidade dos Dados

A análise do desvio padrão revela padrões distintos de dispersão: Ceará (0,29), Goiás (0,28), Pernambuco (0,30) e Rio Grande do Sul (0,29) apresentam a menor variabilidade, indicando maior

homogeneidade no comportamento da inadimplência. Paraná (1,03) e Rio de Janeiro/ES (1,03) mostram a maior dispersão, sugerindo a existência de sub-regiões com comportamentos bastante distintos. As demais regiões apresentam dispersão moderada, entre 0,57 (Bahia) e 0,88 (Centro-Oeste). Bahia (0,57) e Santa Catarina (0,59) apresentam dispersão ligeiramente superior ao grupo de menor variabilidade. Minas Gerais (0,87), Nordeste (0,87) e Norte (0,85) mostram níveis similares de dispersão moderada. São Paulo (0,85) apresenta variabilidade equivalente a outras grandes regiões.

4.1.3. Análise do PMR Após Implementação

Após intervenção de 12 meses, que consistiu na implantação de painéis analíticos no Power BI, desenvolvidos para classificar automaticamente os títulos a receber por nível de risco. Esses dashboards permitiram à equipe de cobrança priorizar ações com base em critérios objetivos, concentrando esforços nos casos mais críticos. A visualização intuitiva dos dados facilitou a identificação de padrões e anomalias, agilizando a tomada de decisão.

Paralelamente, foi implementado um algoritmo proprietário para cálculo de limites de crédito, que automatizou o processo de análise considerando múltiplas variáveis: score de crédito, histórico de pagamentos, renda do cliente e comportamento de consumo. Essa ferramenta reduziu a subjetividade nas decisões de concessão, estabelecendo limites mais adequados ao perfil de risco de cada cliente.

Para garantir a efetiva adoção dessas soluções tecnológicas, um programa abrangente de capacitação foi conduzido com 72 colaboradores das áreas financeira e de crédito. Chegamos nos resultados descritos na Tabela 23.

Tabela 23

Análise de dados PMR após implementação

Região	Qtd Clientes	Desvio Padrão	PMR Médio
Ceará	829	2,93	74,37
Nordeste (outros)	1299	2,93	74,45
Bahia	1642	5,85	79,71
Centro-Oeste	1008	2,88	84,29
Goiás	817	2,89	84,43
Rio Grande do Sul	779	2,95	84,44
Paraná	1631	10,4	84,54
Norte	1362	2,89	84,56
Minas Gerais	2517	5,54	87,91
São Paulo	4010	8,53	88,47
Rio de Janeiro e Espírito Santo	1591	5,79	89,32
Santa Catarina	1600	5,72	89,46
Pernambuco	777	2,93	94,61

Fonte: Dados extraídos do ERP e processados no *Databricks*

Os dados analisados revelam padrões distintos no desempenho do Prazo Médio de Recebimento entre as diferentes regiões brasileiras. Observa-se que:

- As regiões Nordeste e Ceará apresentaram os melhores resultados, com PMR abaixo de 75 dias e baixa variabilidade ($DP \approx 2,93$), indicando processos consistentes de cobrança. Em contraste, Pernambuco registrou o maior PMR (94,61 dias), apesar de sua baixa dispersão, sugerindo que fatores estruturais podem estar impactando uniformemente toda a região.
- As regiões Centro-Oeste, Norte e Sul demonstraram desempenho intermediário, com PMR entre 84-85 dias e variabilidade moderada, exceto pelo Paraná, que apresentou alta dispersão ($DP=10,40$). Essa oscilação no Paraná merece investigação mais aprofundada, pois pode indicar diferenças significativas entre sub-regiões ou tipos de clientes.
- As regiões economicamente mais desenvolvidas - Minas Gerais, Rio de Janeiro/ES, Santa Catarina e São Paulo - mantiveram PMR elevados (acima de 87 dias), com variabilidade considerável. São Paulo, em particular, mostrou a segunda maior dispersão ($DP=8,53$), refletindo possivelmente a diversidade de seu parque industrial e comercial.

A análise não identificou relação direta entre o tamanho da amostra e o desempenho do PMR, indicando que fatores regionais específicos têm maior influência nos resultados do que simplesmente o volume de operações.

4.1.4. Análise do Inadimplência Após implementação

Após 12 meses da intervenção proposta no grupo selecionado, foram obtidos os seguintes resultados na tabela 24.

Tabela 24

Análise de dados de Inadimplência Após- implementação

Região	Desvio Padrão	Inadimplência Média %
Bahia	0,62	1,46
Nordeste (outros)	0,90	1,98
Norte	0,89	1,99
Pernambuco	0,38	2,01
Centro-Oeste	0,88	2,02
Santa Catarina	0,63	2,51
Minas Gerais	0,89	2,99
Ceará	0,36	3,00
Paraná	1,07	3,03
Rio de Janeiro e Espírito Santo	1,07	3,04
São Paulo	0,87	3,38
Goiás	0,38	3,99
Rio Grande do Sul	0,37	3,99

Fonte: Dados extraídos do ERP e processados no *Databricks*

Os dados revelam uma distribuição heterogênea da inadimplência média entre as diferentes regiões brasileiras, acompanhada por distintos níveis de variabilidade interna, conforme relacionado a seguir:

- As regiões Nordeste (outros) (1,98%), Norte (1,99%) e Bahia (1,46%) apresentam os menores índices de inadimplência, porém com desvios padrão relativamente elevados (0,90; 0,89 e 0,62 respectivamente). Esse padrão sugere que, embora a média seja favorável, existem bolsões de maior risco dentro dessas regiões. Pernambuco (2,01%) e Centro-Oeste (2,02%) completam este grupo, mostrando valores próximos à média nacional inferior.
- Santa Catarina (2,51%) se destaca com um perfil distinto, apresentando inadimplência moderada e baixa dispersão (0,63), indicando maior uniformidade no comportamento de pagamento. Minas Gerais (2,99%) e Ceará (3,00%) formam um subgrupo com índices mais elevados, mas ainda abaixo da média nacional superior.
- Goiás (3,99%) e Rio Grande do Sul (3,99%) lideram os índices mais preocupantes, porém com baixíssima variabilidade (0,38 e 0,37 respectivamente), sugerindo um problema estrutural generalizado. São Paulo (3,38%), Paraná (3,03%) e Rio de Janeiro/ES (3,04%) apresentam valores elevados com alta dispersão (0,87 a 1,07), indicando realidades muito distintas dentro dessas regiões economicamente complexas.

4.1.5 Resultados a partir da Análise da Variância (ANOVA)

A heterogeneidade observada entre as regiões não foi meramente descritiva; foi, por sua vez, submetida a um escrutínio estatístico. A Análise de Variância (ANOVA), empregada para comparar as médias de mais de dois grupos, confirmou que as diferenças observadas entre as regiões eram estatisticamente significativas ($F=4,32$; $p=0,002$). O baixo valor de 'p' (inferior a 0,05) nesta análise refuta a hipótese nula de que não haveria diferenças entre as médias regionais, permitindo inferir que os fatores contextuais específicos de cada localidade, ainda que não totalmente explicitados, desempenharam um papel crucial na modulação da eficácia da intervenção, inclusive na forma como as equipes absorveram o treinamento e aplicaram as ferramentas de Power BI e o algoritmo de crédito.

A variabilidade observada no impacto da intervenção, tal como evidenciado pela ANOVA, é um achado de grande relevância, pois destaca que a política, embora eficaz em termos gerais, não opera em um vácuo contextual, mas é influenciada pelas particularidades locais, sejam elas relacionadas à infraestrutura, à cultura organizacional, ou à capacidade de adaptação das equipes à nova tecnologia e metodologia de trabalho.

Além disso, as variações regionais foram analisadas por meio de uma ANOVA, que indicou diferenças significativas entre as regiões no Grupo de Intervenção ($F = 4,32$; $p = 0,002$). Por outro lado, o Grupo pré intervenção não apresentou variações relevantes ($F = 1,12$; $p = 0,36$), o que confirma que, na ausência da intervenção, os níveis de inadimplência permaneceram estáveis, independentemente da região

5 AVALIAÇÃO

Como parte do estudo, foi separado um grupo que não sofreu a intervenção com o objetivo de avaliar se o resultado após a intervenção é de fato oriundo das mudanças propostas nesse estudo. A randomização dos participantes entre os grupos pré e pós-intervenção é uma das estratégias mais eficazes para assegurar a equivalência estatística inicial entre os grupos, reduzindo vieses de seleção e aumentando a validade interna do estudo (Friedman, Furberg, & DeMets, 2010). Além disso, a aplicação de pré-testes e pós-testes possibilita a avaliação da evolução dos participantes ao longo do tempo, permitindo comparar se as mudanças observadas no grupo pós-intervenção

demonstram melhorias significativas em relação ao grupo pré-intervenção— que não recebeu a intervenção ou foi submetido a uma condição neutra —, as evidências tornam-se mais robustas para atribuir os efeitos diretamente à intervenção, minimizando a influência de fatores externos (Polit & Beck, 2021).

5.1. Avaliação do PMR

5.1.1. Análise comparativa de dados de PMR após implementação

A Tabela 25 apresenta a comparação das etapas antes e depois da implementação. Do grupo que sofreu a intervenção

Tabela 25

Comparação entre PMR antes e depois da implementação

Região	Antes	Depois	Aumento/ Redução em dias	Aumento /redução em %
Ceará	74,95	74,37	- 0,58	-0,77%
Nordeste (outros)	74,96	74,45	- 0,51	-0,68%
Bahia	80,20	79,71	- 0,49	-0,61%
Centro-Oeste	84,78	84,29	- 0,49	-0,58%
Goiás	84,97	84,43	- 0,54	-0,64%
Rio Grande do Sul	84,97	84,44	- 0,53	-0,62%
Norte	85,03	84,56	- 0,47	-0,55%
Paraná	85,08	84,54	- 0,54	-0,63%
Minas Gerais	88,41	87,91	- 0,50	-0,57%
São Paulo	88,95	88,47	- 0,48	-0,54%
Rio de Janeiro e Espírito Santo	89,86	89,32	- 0,54	-0,60%
Santa Catarina	89,96	89,46	- 0,50	-0,56%
Pernambuco	95,13	94,61	- 0,52	-0,55%

Fonte: Dados extraídos do ERP e processados no *Databricks*

Os dados revelam uma melhora nos prazos médios de recebimento em todas as regiões analisadas após a implementação das medidas intervencionistas. A redução média nacional foi de 0,52 dias no PMR, equivalente a -0,60% em termos percentuais.

Quando analisadas as variações percentuais, observa-se uma faixa ainda mais estreita de resultados, variando entre -0,54% e -0,77%. Essa consistência nos percentuais de redução é particularmente interessante, pois sugere um padrão de resposta similar em regiões com características econômicas e perfis de clientes bastante distintos.

Dentre os destaques:

- O Ceará apresentou a maior redução percentual (-0,77%)

- O Nordeste (outros) obteve a segunda maior redução (-0,67%)
- Bahia e Centro-Oeste tiveram as menores reduções percentuais (-0,61% e -0,58%, respectivamente)

Essa distribuição revela que as regiões que já possuíam os melhores desempenhos iniciais (Ceará e Nordeste (outros)) foram justamente aquelas que apresentaram as maiores reduções percentuais, sugerindo uma possível relação entre a eficácia das intervenções e a maturidade prévia dos processos de gestão de recebíveis.

Uma análise da posição relativa das regiões antes e após as intervenções revela que a ordem classificatória permaneceu essencialmente inalterada. Os principais destaques deste aspecto incluem:

- Pernambuco manteve-se como a região com maior PMR (94,61 dias após a intervenção)
- Ceará e Nordeste (outros) conservaram suas posições como regiões com os melhores desempenhos (74,37 e 74,45 dias, respectivamente)
- Não houve alterações significativas nas posições intermediárias do ranking

Reduzir o Prazo Médio de Recebimento (PMR), mesmo que em apenas um dia, é relevante porque impacta diretamente o capital de giro e a liquidez da empresa. Essa redução antecipa a entrada de caixa, diminui a necessidade de financiamento externo e, conseqüentemente, os custos financeiros associados. Além disso, possibilita maior segurança no fluxo de caixa, reduz o risco de inadimplência e gera um efeito acumulado significativo, uma vez que, ao considerar o volume anual de vendas, um único dia pode representar valores expressivos disponíveis para reinvestimento ou negociação com fornecedores.

5.1.2 Resultados de PMR do grupo sem intervenção

Passados 12 meses após o período de intervenção, os dados do PMR do grupo que não sofreu a intervenção são apresentados na Tabela 26.

Tabela 26

Análise de dados de PMR Pré-intervenção Antes e Depois

Região	Antes	Depois	Aumento	Aumento %
São Paulo	87,03	87,52	0,49	0,56%
Bahia	65,07	67,53	2,45	3,77%
Nordeste (outros)	84,91	87,35	2,45	2,88%
Rio Grande do Sul	65,08	67,53	2,45	3,76%
Rio de Janeiro e Espírito santo	88,21	90,69	2,48	2,81%
Minas Gerais	77,44	79,94	2,50	3,23%
Paraná	84,17	86,67	2,50	2,97%
Santa Catarina	74,95	77,46	2,50	3,34%
Ceará	80,59	83,1	2,51	3,12%
Centro-Oeste	85,1	87,62	2,52	2,96%
Goiás	85,07	87,6	2,53	2,97%

Norte	84,95	87,48	2,53	2,97%
Pernambuco	65,04	67,57	2,53	3,89%

Fonte: Dados extraídos do ERP e processados no *Databricks*

Os dados demonstram que todas as regiões analisadas tiveram um aumento absoluto e percentual nos índices medidos, embora em magnitudes distintas. O aumento absoluto médio ficou em torno de 2,48 dias, enquanto a variação percentual média foi de 3,04%, indicando uma tendência de crescimento moderado e generalizado.

Nota-se que os incrementos absolutos foram relativamente homogêneos, variando entre 2,45 (Bahia, Nordeste, Rio Grande do Sul) e 2,53 (Goiás, Norte, Pernambuco). Essa pequena amplitude sugere que, em termos brutos, as regiões avançaram de forma semelhante. No entanto, quando analisamos os percentuais, as diferenças tornam-se mais evidentes, pois dependem do valor inicial ("pré").

Pernambuco emergiu como a região com o maior aumento percentual (3,89%), seguido pela Bahia (3,77%) e Rio Grande do Sul (3,76%). Esses resultados chamam a atenção porque partem de bases mais baixas (valores iniciais próximos a 65), o que amplifica o impacto relativo do crescimento.

Minas Gerais (3,23%), Santa Catarina (3,34%) e a região Centro-Oeste (2,96%) apresentaram crescimentos percentuais próximos à média nacional. Minas Gerais, por exemplo, partiu de 77,44 para 79,94, um aumento de 2,50 pontos. Santa Catarina, por sua vez, saiu de 74,95 para 77,46, também com um incremento de 2,50.

O caso de São Paulo é digno de análise mais aprofundada. Enquanto todas as outras regiões tiveram aumentos acima de 2,45 pontos, São Paulo avançou apenas 0,49.

5.1.3 Comparação de PMR do Pós-intervenção x Pré-intervenção

A utilização de um Grupo pré-intervenção oferece um parâmetro confiável para entender o que seria esperado na ausência da política ou programa testado. Sem essa comparação, qualquer melhoria (ou deterioração) observada poderia ser erroneamente atribuída à intervenção, quando, na realidade, poderia ser resultado de tendências preexistentes, sazonalidades ou outros fatores alheios à ação analisada. Por outro lado, o grupo de intervenção, que é diretamente impactado pela medida em avaliação, fornece os dados necessários para mensurar o efeito líquido da política, ou seja, o quanto ela de fato contribuiu para alterar o indicador em questão. Além disso, a comparação entre os dois grupos permite identificar heterogeneidades regionais na resposta à intervenção.

Portanto, a análise comparativa entre Grupo pré-intervenção e grupo de pós-intervenção passados 12 meses, não só ratifica a eficácia de uma política, mas também refina sua aplicabilidade, destacando em quais contextos ela é mais efetiva, quais populações se beneficiam prioritariamente e em que prazos os resultados podem ser esperados. Essa abordagem assegura que decisões baseadas em evidências sejam tomadas, evitando a alocação inadequada de recursos ou a perpetuação de estratégias ineficazes.

Tabela 27

Comparação em % do PMR passados 12 meses entre o grupo de pós-intervenção e o grupo pré-intervenção

Região	Pós	Pré
Bahia	-0,61%	3,77%
Ceará	-0,77%	3,12%
Centro-Oeste	-0,58%	2,96%

Goiás	-0,63%	2,97%
Minas Gerais	-0,56%	3,23%
Nordeste (outros)	-0,67%	2,88%
Norte	-0,56%	2,97%
Paraná	-0,64%	2,97%
Pernambuco	-0,54%	3,89%
Rio de Janeiro e Espírito santo	-0,60%	2,81%
Rio Grande do Sul	-0,62%	3,76%
Santa Catarina	-0,56%	3,34%
São Paulo	-0,54%	0,56%

Fonte: Dados extraídos do ERP e processados no *Databricks*

Os dados analisados evidenciaram uma tendência clara: enquanto o Grupo pré intervenção registrou aumentos percentuais positivos em todas as regiões, variando de 0,56% a 3,89%, o Grupo de Intervenção apresentou variações negativas, entre -0,54% e -0,77%. Esse padrão sugere que a intervenção pode ter exercido um efeito redutor sobre a PMR, uma vez que, na ausência da intervenção, o indicador apresentou crescimento.

O objetivo da análise foi comparar estatisticamente as médias e dispersões entre os dois grupos, avaliar a significância das diferenças observadas, identificar padrões regionais que possam explicar variações na eficácia da intervenção e discutir as implicações práticas dos resultados.

No que se refere à tendência central e à dispersão, o Grupo de Intervenção apresentou uma média de -0,61%, com desvio padrão de 0,07%. O valor máximo foi de -0,77% no Ceará, enquanto o mínimo foi de -0,54%, observado em Pernambuco e São Paulo. Esses resultados indicam uma pequena variabilidade, com todas as regiões mostrando quedas próximas a -0,6%, sugerindo uma resposta homogênea à política implementada. Por outro lado, o Grupo pré intervenção teve uma média de 3,04%, com desvio padrão de 0,87%. O menor crescimento foi registrado em São Paulo (+0,56%), configurando-se como um outlier, enquanto o maior ocorreu em Pernambuco (+3,89%). Assim, o Grupo pré intervenção apresentou maior variabilidade, com valores positivos e mais dispersos.

A comparação entre os grupos revela que, na ausência da intervenção, a PMR tende a subir, enquanto, com a intervenção, observa-se uma redução. Para verificar se essa diferença entre os grupos era estatisticamente significativa, foi aplicado um teste t para amostras independentes. A hipótese nula afirmava não haver diferença significativa entre os grupos, enquanto a hipótese alternativa propunha que o Grupo de Intervenção apresentava médias significativamente menores. O teste indicou uma diferença média de -3,65%, com um valor-p inferior a 0,0001, demonstrando alta significância estatística. O intervalo de confiança de 95% variou de -4,12% a -3,18%. Assim, rejeita-se a hipótese nula, concluindo-se que a intervenção reduziu o PMR em comparação ao cenário sem tratamento.

A baixa variabilidade no Grupo de Intervenção sugere que a política funcionou de forma similar em diferentes contextos regionais, enquanto a maior dispersão no Grupo pré reforça a influência de fatores locais na PMR quando não há intervenção.

As implicações desses resultados para as políticas públicas são relevantes. Em primeiro lugar, a intervenção demonstrou ser eficaz e deve ser considerada para ampliação. Em segundo, regiões com maior crescimento natural da PMR, como Pernambuco, podem se beneficiar mais da

política, justificando sua priorização. Por fim, no caso de São Paulo, onde o crescimento no Grupo pré intervenção foi relativamente baixo (+0,56%).

5.2. Avaliação da Inadimplência

5.2.1. Análise comparativa de dados da Inadimplência após implementação

A Tabela 28 apresenta a comparação de dados de inadimplência antes e depois da implementação do grupo que sofreu a intervenção

Tabela 28

Análise comparativa de dados de Inadimplência após implementação

Região	Antes	Depois	Redução	Redução %
Bahia	2,02	1,46	- 0,55	-27,43%
Ceará	3,55	3,00	- 0,56	-15,73%
Centro-Oeste	2,57	2,02	- 0,55	-21,40%
Goiás	4,55	3,99	- 0,56	-12,25%
Minas Gerais	3,54	2,99	- 0,55	-15,59%
Nordeste (outros)	2,54	1,98	- 0,56	-21,97%
Norte	2,55	1,99	- 0,56	-21,85%
Paraná	3,57	3,03	- 0,54	-15,15%
Pernambuco	2,56	2,01	- 0,54	-21,23%
Rio de Janeiro e Espírito santo	3,57	3,04	- 0,54	-15,07%
Rio Grande do Sul	4,54	3,99	- 0,55	-12,17%
Santa Catarina	3,07	2,51	- 0,56	-18,26%
São Paulo	3,94	3,38	- 0,55	-14,08%

Fonte: Dados extraídos do ERP e processados no *Databricks*

Os dados coletados após doze meses de implementação das medidas intervencionistas revelam variações significativas nos índices de inadimplência em todas as treze regiões analisadas. A comparação entre os valores pré e pós-intervenção mostra um cenário complexo e multifacetado, com padrões distintos emergindo conforme a localidade geográfica.

- Na região Nordeste, os índices de inadimplência apresentaram redução de 2,54% para 1,98%, representando uma diminuição absoluta de 0,56 ponto percentual. A Bahia, que integra esta região, registrou queda de 2,02% para 1,46%, equivalente a 0,56 ponto percentual. Pernambuco, por sua vez, mostrou variação de 2,56% para 2,01%, com redução de 0,55 ponto percentual. O Ceará, que inicialmente apresentava o maior índice na região com 3,55%, reduziu para 3,00%, uma diminuição de 0,55 ponto percentual.
- A região Norte apresentou comportamento similar, com o índice geral passando de 2,55% para 1,99%, redução de 0,56 ponto percentual. No Centro-Oeste, a inadimplência média diminuiu de 2,57% para 2,02%, queda de 0,55 ponto

percentual. Goiás, que possuía o maior índice nesta região com 4,55%, reduziu para 3,99%, uma diminuição de 0,56 ponto percentual.

- No Sudeste, os resultados mostraram padrões distintos entre os estados. Minas Gerais registrou redução de 3,54% para 2,99%, equivalente a 0,55 ponto percentual. O Rio de Janeiro e Espírito Santo apresentaram variação de 3,57% para 3,04%, diminuição de 0,53 ponto percentual. São Paulo, que possuía o maior índice regional com 3,94%, reduziu para 3,38%, queda de 0,56 ponto percentual.
- A região Sul demonstrou comportamentos variados. O Paraná reduziu sua inadimplência de 3,57% para 3,03%, diminuição de 0,54 ponto percentual. Santa Catarina passou de 3,07% para 2,51%, redução de 0,56 ponto percentual. O Rio Grande do Sul, que apresentava o maior índice regional com 4,54%, diminuiu para 3,99%, equivalente a 0,55 ponto percentual.

Quando analisadas as variações percentuais, observa-se que a região Nordeste apresentou redução relativa de 22,05%, com a Bahia mostrando a maior queda percentual entre todas as regiões (27,72%). O Norte registrou diminuição percentual de 21,96%, enquanto o Centro-Oeste reduziu 21,40% seus índices. No Sudeste, as reduções percentuais variaram entre 14,84% no Rio de Janeiro e Espírito Santo a 15,54% em Minas Gerais. São Paulo apresentou queda percentual de 14,21%. Na região Sul, o Paraná reduziu 15,13%, Santa Catarina 18,24% e Rio Grande do Sul 12,11%.

Em termos relativos, as maiores quedas percentuais ocorreram na Bahia (27,72%), Nordeste (22,05%) e Norte (21,96%), enquanto as menores reduções relativas foram observadas no Rio Grande do Sul (12,11%), São Paulo (14,21%) e Rio de Janeiro e Espírito Santo (14,84%).

Os dados demonstram que todas as regiões apresentaram reduções em seus índices de inadimplência, com variações absolutas concentradas entre 0,53 e 0,56 ponto percentual. As variações percentuais mostraram maior dispersão, indo de 12,11% a 27,72%. As regiões que inicialmente apresentavam os menores índices de inadimplência (Nordeste e Norte) foram as que mostraram as maiores reduções percentuais, enquanto aquelas com os maiores índices iniciais (como Rio Grande do Sul e Goiás) tiveram as menores reduções percentuais.

A consistência das reduções absolutas em torno de 0,55 ponto percentual em quase todas as regiões sugere um efeito padronizado das intervenções, independentemente do tamanho da região ou do nível inicial de inadimplência. Entretanto, a variação nas reduções percentuais indica que o impacto relativo foi maior nas regiões que já possuíam melhores indicadores prévios.

São Paulo, Rio de Janeiro e Minas Gerais apresentaram comportamentos similares, com reduções absolutas próximas à média geral (0,53 a 0,56 ponto percentual) e reduções percentuais moderadas (14,21% a 15,54%). As regiões com economias mais localizadas (como Santa Catarina e Paraná) mostraram padrões distintos entre si, com Santa Catarina tendo redução percentual maior (18,24%) que Paraná (15,13%), apesar de partirem de níveis iniciais similares.

5.2.2. Resultados de Inadimplência do grupo sem intervenção

Passados 12 meses do período de nossa pesquisa, o grupo pré-intervenção seguiu os seguintes resultados:

Tabela 29

Análise de dados de Inadimplência Pré-intervenção Antes e Depois

Região	Antes	Depois	Aumento/ diminuição	Aumento/ diminuição %
Santa Catarina	1,53	1,53	0,00	0,00%
Goiás	1,54	1,54	0,00	0,00%
Centro-Oeste	1,55	1,50	- 0,04	-2,83%
Bahia	1,56	1,55	- 0,01	-0,44%

Nordeste (outros)	1,56	1,60	0,04	2,58%
Norte	2,54	2,54	0,00	0,00%
Minas Gerais	2,59	2,59	0,00	0,00%
Paraná	3,01	3,01	0,00	0,00%
São Paulo	3,22	3,22	0,00	0,00%
Pernambuco	3,56	3,55	0,00	0,00%
Ceará	3,65	3,63	- 0,02	-0,53%
Rio de Janeiro e Espírito santo	4,55	4,57	0,02	0,49%
Rio Grande do Sul	4,55	4,56	0,00	0,00%

Fonte: Dados extraídos do ERP e processados no *Databricks*

A análise dos dados evidencia que os índices avaliados permaneceram, em grande medida, estáveis no período analisado, apresentando apenas variações marginais na maioria das regiões. A média geral de variação foi de -0,13%, sinalizando um cenário de manutenção com pequenas oscilações. Entre os destaques positivos, observa-se que o Centro-Oeste apresentou a maior redução percentual, de -2,83%, caindo de 1,55 para 1,50, seguido por quedas menores no Ceará (-0,53%) e na Bahia (-0,44%). Esses resultados sugerem que nessas localidades a intervenção ou as condições do período analisado impactaram de forma mais significativa, resultando em retração mais acentuada.

No sentido oposto, algumas regiões registraram crescimento, ainda que moderado. O Nordeste (outros) destacou-se como a região de maior variação negativa, com aumento de 2,58%, passando de 1,56 para 1,60, destoando do padrão geral de estagnação ou leve queda. Também se verificou incremento no Rio de Janeiro e Espírito Santo (+0,49%), ainda que de forma menos significativa.

Em síntese, o panorama revela que os índices permaneceram amplamente estáveis, com predominância de variações pouco expressivas. O Centro-Oeste, a Bahia e o Ceará se destacaram pelas reduções mais relevantes, enquanto o Nordeste e, em menor grau, o Rio de Janeiro e Espírito Santo apresentaram crescimento, configurando-se como exceções dentro do padrão geral observado.

5.2.3. Comparação de Inadimplência do Pós-intervenção x Pré-intervenção

A utilização de um Grupo pré-intervenção na análise de indicadores financeiros, como a taxa de inadimplência, é fundamental para distinguir entre os efeitos reais de uma intervenção e as variações que ocorreriam naturalmente no mercado. Por outro lado, o grupo de intervenção, que foi submetido a ações específicas – como reestruturação de prazos, políticas de renegociação ou programas de educação financeira –, fornece os dados necessários para mensurar o impacto líquido da estratégia, ou seja, o quanto ela verdadeiramente contribuiu para alterar o perfil de crédito da população analisada.

Na tabela 30 podemos ver a comparação entre o grupo pré e pós passados 12 meses de implementação.

Tabela 30

Comparação em % da Inadimplência passados 12 meses entre o grupo de pós intervenção e o grupo pré-intervenção

Região	Pós	Pré
Bahia	-27,43%	-0,44%
Ceará	-15,73%	-0,53%
Centro-Oeste	-21,40%	-2,83%
Goiás	-12,25%	-0,22%
Minas Gerais	-15,59%	-0,02%
Nordeste (outros)	-21,97%	2,58%
Norte	-21,85%	0,10%
Paraná	-15,15%	-0,07%
Pernambuco	-21,23%	-0,03%
Rio de Janeiro e Espírito santo	-15,07%	0,49%
Rio Grande do Sul	-12,17%	0,02%
Santa Catarina	-18,26%	-0,02%
São Paulo	-14,08%	-0,03%

Fonte: Dados extraídos do ERP e processados no *Databricks*

Os resultados obtidos evidenciam diferenças marcantes entre os grupos analisados. O Grupo Pós-Intervenção apresentou uma média de redução da inadimplência de -17,79%, com a maior queda observada na Bahia (-27,43%) e a menor no Rio Grande do Sul (-12,17%). O desvio padrão de 4,85% indica uma variabilidade regional considerável, sugerindo que os efeitos da intervenção não foram homogêneos em todo o território.

Em contraste, o Grupo Pré-Intervenção apresentou uma média de variação praticamente estável, de -0,18%, com a maior elevação registrada no Nordeste (+2,58%) e a maior redução no Centro-Oeste (-2,83%). O desvio padrão neste grupo foi de 0,95%, revelando uma dispersão bem menor em comparação ao grupo submetido à intervenção. Esse cenário reforça a interpretação de que, enquanto o Grupo Pós registrou quedas expressivas, o Grupo Pré permaneceu praticamente inalterado.

A comparação estatística entre os grupos, realizada por meio do teste t, confirmou que a diferença observada foi altamente significativa ($p < 0,0001$), com uma diferença média de 17,61 pontos percentuais. O intervalo de confiança de 95% variou entre -19,88% e -15,34%, reforçando a robustez da análise e a confiabilidade da inferência estatística.

A análise de correlação entre o efeito da intervenção e o cenário inicial, conduzida por meio de regressão linear, identificou uma correlação moderada ($r = -0,48$) entre a redução no Grupo Pós-Intervenção e a tendência de variação no Grupo Pré. Esse achado sugere que as regiões onde havia indícios de crescimento da inadimplência sem intervenção, como no caso do Nordeste (+2,58%), foram justamente aquelas que apresentaram reduções mais expressivas após a implementação da política, exemplificadas pela Bahia (-27,43%) e pelo Nordeste como um todo (-21,97%).

Os resultados demonstram, portanto, que a política implementada foi altamente eficaz, promovendo uma redução substancial da inadimplência em todas as regiões analisadas. A queda média de 17,79% no Grupo Pós contrasta fortemente com a estabilidade observada no Grupo Pré,

evidenciando que o efeito não pode ser atribuído a fatores externos ou a tendências naturais, mas sim à intervenção realizada.

Adicionalmente, a análise identificou três padrões regionais distintos de eficácia:

Alta eficácia (reduções superiores a 20%): Bahia (-27,43%), Nordeste (-21,97%), Norte (-21,85%), Centro-Oeste (-21,40%) e Pernambuco (-21,23%). Nessas regiões, a política apresentou resultados bastante expressivos, possivelmente relacionados à maior vulnerabilidade econômica inicial e à maior adesão aos programas de renegociação.

Média eficácia (reduções entre 15% e 20%): Santa Catarina (-18,26%), Minas Gerais (-15,59%), Ceará (-15,73%), Paraná (-15,15%) e Rio de Janeiro e Espírito Santo (-15,07%), onde a resposta foi consistente, embora menos intensa que nos casos anteriores.

Baixa eficácia (reduções inferiores a 15%): Goiás (-12,25%), Rio Grande do Sul (-12,17%) e São Paulo (-14,08%), indicando que, nessas localidades, o impacto da intervenção, embora positivo, foi mais limitado.

5.3 Avaliação dos colaboradores sobre ferramentas utilizadas

A aplicação do questionário foi realizada de forma remota, por meio de um formulário digital autoadministrado, via Microsoft forms. Essa escolha metodológica teve como principal objetivo garantir a acessibilidade dos respondentes, padronizar o processo de coleta de dados e assegurar que todos os participantes tivessem tempo e flexibilidade suficientes para responder às perguntas com atenção e sinceridade. A utilização de um formulário online permitiu que os colaboradores acessassem o instrumento por diferentes dispositivos (computadores, tablets e smartphones), sem a necessidade de deslocamento físico ou agendamento específico, o que se mostrou particularmente eficiente para alcançar um público profissional com rotinas dinâmicas e horários distintos.

A adesão à pesquisa foi total. Todos os 73 participantes responderam voluntariamente ao questionário, o que representa uma taxa de resposta de 100%. Esse índice de participação pode ser atribuído a diversos fatores, entre eles, a clareza da proposta da pesquisa, o comprometimento dos colaboradores com o processo de melhoria contínua na organização, e a percepção de relevância do tema abordado — o uso de ferramentas tecnológicas voltadas à análise de dados no contexto da gestão financeira. Outro fator importante foi o intervalo temporal entre o início da intervenção e a aplicação do instrumento: o questionário estruturado foi disponibilizado após um período de 12 meses desde a implementação das ferramentas de *Data Analytics*. Esse intervalo foi estrategicamente definido para permitir que os participantes tivessem uma experiência concreta e contínua com os recursos tecnológicos, em situações reais de trabalho, antes de emitirem suas opiniões e percepções.

Com esse intervalo, buscou-se evitar respostas superficiais ou baseadas em primeiras impressões. O objetivo era capturar percepções consolidadas, baseadas na vivência cotidiana, no uso recorrente das ferramentas e na integração prática dessas tecnologias nos fluxos operacionais das equipes. Dessa forma, os dados obtidos apresentam maior consistência e refletem, com maior fidelidade, os impactos percebidos pelos usuários em suas atividades profissionais.

Para garantir o rigor metodológico e a confiabilidade das informações coletadas, todas as respostas foram tratadas de maneira absolutamente anônima. A anonimização dos dados teve como propósito proteger a identidade dos respondentes e promover um ambiente de liberdade para manifestação de opiniões sinceras e críticas construtivas. Essa medida também foi fundamental para eliminar possíveis vieses relacionados à hierarquia organizacional, uma vez que os participantes poderiam se sentir à vontade para compartilhar tanto os pontos positivos quanto as limitações percebidas durante o uso das ferramentas digitais.

Tabela 31

Resultado da pesquisa de implementação com os usuários da intervenção

Questão	Pergunta	Média	Mínimo	Máximo	Moda
---------	----------	-------	--------	--------	------

1	O painel do Power BI (classificação de títulos por risco) melhorou a eficiência na priorização de clientes para cobrança.	8,30	6	10	8
2	O algoritmo automatizado de limite de crédito reduziu o meu tempo gasto na análise e concessão de crédito	8,47	6	10	10
3	Os dashboards do Power BI facilitaram o acesso a informações atualizadas para decisões rápidas.	8,82	7	10	10
4	As ferramentas contribuíram para a redução da inadimplência na minha unidade/região.	8,49	6	10	8
5	As ferramentas foram adaptadas aos processos existentes.	8,47	7	10	7
6	Eu recomendaria a expansão dessas ferramentas para outras unidades da empresa.	8,55	6	10	8

Fonte: Dados coletados através de ferramenta de questionário

5.3.1. Eficiência na Prioridade de Cobrança (Painel Power BI)

Com uma média de 8,30, essa questão indicou uma percepção majoritariamente positiva em relação à eficácia do painel de classificação de títulos por risco. A moda (8) sugere que essa foi a resposta mais comum entre os participantes, confirmando consistência com a média. O intervalo de variação (6 a 10) mostra alguma dispersão, com a presença de avaliações mais conservadoras, porém ainda dentro de um espectro de percepção favorável.

5.3.2. Redução do Tempo na Análise de Crédito (Algoritmo Automatizado)

Essa foi uma das questões com maior consistência e alta avaliação média (8,47). O fato de a moda ser 10 revela que um número expressivo de participantes percebeu impacto máximo do algoritmo na otimização do processo de concessão de crédito. Ainda que a variação mínima tenha sido 6, a tendência central aponta para uma aceitação expressiva da tecnologia.

5.3.3. Acesso Facilitado a Informações Atualizadas (Dashboards Power BI)

Com a maior média entre todas as questões (8,82) e moda também em 10, esse item destacou-se como o aspecto mais bem avaliado da intervenção tecnológica. Isso demonstra que os dashboards implementados foram altamente eficazes na entrega de informações em tempo real, atendendo a uma demanda crítica dos gestores financeiros por maior agilidade e precisão no processo decisório.

5.3.4. Redução da Inadimplência com Apoio das Ferramentas

A média de 8,49 e moda em 8 indicam que a maioria dos respondentes notou impacto concreto na gestão da inadimplência. Embora os dados demonstrem leve dispersão (com avaliações entre 6 e 10), os valores reforçam uma percepção global positiva, especialmente em relação ao uso combinado de dados para antecipação de riscos e gestão proativa da carteira de clientes.

5.3.5. Adaptação das Ferramentas aos Processos Existentes

Esta questão apresentou média de 8,47, idêntica à questão 2, mas com moda em 7, o que sugere uma leve maior variabilidade nas percepções dos usuários em relação à adequação das ferramentas ao fluxo de trabalho preexistente. Isso pode indicar desafios pontuais de transição — como a substituição de planilhas manuais por soluções automatizadas —, ainda que a percepção geral tenha permanecido altamente favorável.

5.3.6. Recomendação para Expansão das Ferramentas

Com uma média de 8,55 e moda em 8, esta questão representa o grau de apoio à continuidade e expansão da intervenção para outras unidades da empresa. Os resultados indicam um forte potencial de replicabilidade e validação da proposta entre os usuários, evidenciando que a experiência positiva no uso das ferramentas não foi isolada, mas sim compartilhada amplamente.

A distribuição geográfica dos resultados não segue padrões regionais tradicionais (como Norte-Sul ou Centro-Periferia), mas sim uma lógica mais complexa que combina fatores econômicos locais com características específicas de implementação. Regiões geograficamente próximas, como Paraná e Santa Catarina, apresentaram respostas distintas às mesmas intervenções, enquanto regiões distantes, como Bahia e Santa Catarina, mostraram padrões similares em alguns aspectos.

Os dados coletados permitem ainda observar que não houve casos de regiões que não respondessem às intervenções. Todas as treze regiões analisadas apresentaram reduções em seus índices de inadimplência, variando apenas na intensidade dessas melhorias. Essa consistência sugere que as medidas implementadas tiveram eficácia generalizada, embora com graus variados de impacto conforme o contexto regional.

Os dados também revelam que as regiões que iniciaram o período com maior variabilidade interna nos índices de inadimplência (como São Paulo e Minas Gerais) mantiveram esse padrão ao final dos doze meses, sugerindo que as intervenções não alteraram significativamente a dispersão interna, apenas reduziram os valores médios.

A comparação entre regiões com perfis econômicos distintos (agropecuárias, industriais, de serviços) não revela padrões claros de resposta diferenciada às intervenções. Regiões com estruturas produtivas diversas apresentaram reduções similares em termos absolutos, indicando que o tipo de atividade econômica predominante não foi fator determinante nos resultados obtidos.

5.4 Avaliação das entrevistas dos gestores mediante às proposições

5.4.1 Capacidade de decisão estratégica na gestão do crédito e cobrança

O uso de ferramentas de *Data Analytics* tem promovido uma transformação significativa na forma como as decisões estratégicas relacionadas ao crédito e à cobrança são conduzidas. Através da análise estruturada de grandes volumes de dados, tornou-se possível identificar padrões de comportamento de pagamento, níveis de risco de inadimplência e tendências históricas de desempenho por segmento de clientes.

No âmbito da cobrança, os dados analisados viabilizam a priorização de ações com base no potencial de recuperação, melhorando a alocação de recursos e aumentando a efetividade das estratégias. Além disso, o monitoramento em tempo real de indicadores-chave, como a inadimplência e a perda esperada, tem proporcionado uma tomada de decisão mais ágil e fundamentada, contribuindo para a melhoria do fluxo de caixa e para a redução do risco financeiro. Assim, as ferramentas de *Data Analytics* têm se consolidado como um suporte essencial para decisões mais assertivas, integrando inteligência analítica aos processos financeiros da organização.

De acordo com E1: "O *Data Analytics* nos permitiu substituir decisões intuitivas por análises baseadas em dados históricos e tendências, aumentando a assertividade na concessão de crédito." E2 complementa: "As ferramentas nos ajudam a identificar rapidamente clientes com alto risco de inadimplência, direcionando estratégias de cobrança mais eficazes." Por fim E12 finaliza com o seguinte comentário: "Antes, dependíamos de planilhas estáticas. Agora, com dashboards em tempo real, podemos ajustar estratégias de cobrança diariamente."

Desde a adoção das ferramentas de *Data Analytics* no processo de gestão financeira, observou-se uma transformação significativa na qualidade e na agilidade das informações utilizadas para a tomada de decisão estratégica, especialmente nas áreas de crédito e cobrança. Anteriormente, as decisões eram baseadas em relatórios estáticos, muitas vezes defasados, que exigiam um elevado esforço manual para consolidação, cruzamento e interpretação dos dados. Esse processo, além de

demandar tempo, apresentava elevado risco de inconsistências e falhas humanas, o que comprometia a assertividade das decisões.

Com a implementação de plataformas analíticas, como o Power BI, foi possível integrar diferentes fontes de dados de forma automatizada, garantindo maior confiabilidade, precisão e atualização contínua das informações. Os indicadores passaram a ser monitorados em tempo real, permitindo aos gestores acesso imediato a métricas críticas, como inadimplência, índice de recuperação, aging de títulos e limites de crédito utilizados. Essa disponibilidade instantânea de dados reduziu significativamente o tempo entre a identificação de um problema e a definição de uma ação corretiva.

Além disso, a visualização dos dados por meio de dashboards interativos contribuiu para uma melhor compreensão dos comportamentos da carteira de clientes, possibilitando a identificação de padrões, tendências e anomalias com maior rapidez. As análises se tornaram mais profundas, permitindo simulações e avaliações comparativas entre diferentes grupos e períodos. Como resultado, a qualidade da informação foi elevada, e a capacidade de resposta da gestão financeira tornou-se mais ágil, embasada e estratégica. De acordo com um dos E4: "Antes, levávamos dias para consolidar informações. Agora, em poucos minutos, temos informações atualizadas."

A introdução do *Data Analytics* na gestão do crédito e da cobrança não apenas aprimorou a análise de indicadores tradicionais, como também possibilitou o surgimento de novos indicadores e perspectivas analíticas que antes não estavam disponíveis ou eram de difícil acesso. De acordo com E3, "o que antes demorava semanas para ser consolidado em relatórios manuais, hoje conseguimos visualizar em tempo real com poucos cliques". Ao integrar diferentes bases de dados e aplicar técnicas analíticas avançadas, como segmentação, modelagem preditiva e análise de risco, as organizações passaram a considerar variáveis mais sofisticadas e relevantes para a tomada de decisão. Nesse sentido, E9 complementa: "a segmentação nos deu uma clareza muito maior sobre quais clientes merecem mais atenção imediata e quais têm um risco controlado".

Um exemplo disso é o Risco de Propensão à Inadimplência, construído com base em comportamentos históricos, padrões de pagamento, perfil do cliente e outros dados contextuais. Segundo E1, "esse indicador mudou nossa rotina, porque agora conseguimos antecipar problemas que só seriam percebidos após o atraso". Esse indicador fornece uma visão preditiva do risco futuro, permitindo ações preventivas antes que a inadimplência se concretize. Como destacou E7, "antes nós corríamos atrás do prejuízo, agora conseguimos agir antes do vencimento e oferecer alternativas ao cliente".

Além disso, indicadores como tempo médio de resposta à cobrança (que é medido em algumas unidades), custo por recuperação e nível de recorrência da inadimplência têm ganhado espaço nas análises de desempenho, trazendo uma perspectiva mais ampla e estratégica para a gestão. Na visão de E12, "esses novos indicadores foram essenciais para justificar investimentos em automação do processo de cobrança, mostrando retorno em eficiência". Por fim, E4 reforça: "a análise do custo por recuperação nos ajudou a identificar quais estratégias realmente valem a pena e quais consomem recursos sem trazer resultados". Portanto, o *Data Analytics* não apenas refinou os métodos existentes, como ampliou o repertório de indicadores disponíveis, favorecendo uma abordagem mais preditiva, eficiente e orientada por dados na condução das políticas de crédito e cobrança.

Ferramentas de *Data Analytics* na gestão do crédito e da cobrança, ainda existem desafios e limitações relevantes que impactam a aplicação prática dessas tecnologias no dia a dia das organizações. Um dos principais obstáculos é a qualidade dos dados de origem, que nem sempre estão estruturados ou padronizados de forma adequada, exigindo esforço adicional de limpeza e tratamento antes de serem utilizados nas análises.

Em certos casos, a resistência cultural de parte da equipe à adoção de ferramentas analíticas pode dificultar a incorporação dos insights gerados ao processo decisório. Em linha com um dos

comentários do E8: “A curva de aprendizado para dominar as ferramentas foi um obstáculo inicial para a equipe.”

Com base nas respostas acima, conduzem confirmação da a Proposição 1, na medida em que a utilização de ferramentas de *Data Analytics* na gestão do crédito e da cobrança demonstrou aprimorar de forma significativa a capacidade dos gestores financeiros em tomar decisões estratégicas. Os relatos dos entrevistados reforçam essa constatação: E1 destacou a substituição de decisões intuitivas por análises baseadas em dados históricos, enquanto E2 ressaltou a maior precisão na identificação de clientes com risco de inadimplência, e E12 enfatizou o uso de dashboards em tempo real para ajustes diários nas estratégias de cobrança. Esses depoimentos, somados à evidência da integração de dados e da criação de novos indicadores preditivos, indicam que a gestão se tornou mais ágil, fundamentada e assertiva. Assim, os achados convergem no sentido de validar a proposição de que o *Data Analytics* amplia a assertividade e a efetividade das decisões estratégicas na área de crédito e cobrança.

5.4.2 Melhorias na eficiência na análise de crédito e priorização de clientes na cobrança

Antes da implementação dessas soluções, o processo era majoritariamente manual, exigindo a extração de informações de diferentes sistemas, consolidação em planilhas e análises pontuais baseadas em indicadores estáticos. Esse fluxo demandava um tempo significativo dos analistas, além de estar sujeito a erros operacionais e limitações na profundidade das análises. Com a integração de ferramentas, tornou-se possível automatizar a consolidação de dados e disponibilizar painéis dinâmicos com atualizações em tempo real, permitindo que as análises fossem feitas com maior agilidade e com base em dados sempre atualizados.

Esse ganho de eficiência permitiu que o tempo antes dedicado a tarefas operacionais fosse redirecionado para atividades de maior valor agregado, como o estudo de cenários, a simulação de impactos de concessão de crédito e a definição de estratégias por perfil de cliente. Em termos práticos, o tempo médio para análise de crédito reduziu-se de forma substancial, aumentando a produtividade da equipe e contribuindo para respostas mais ágeis às demandas comerciais. De acordo com E9: "Reduzimos o tempo de análise de minutos para segundos, graças à automação de processos."

Por meio da análise integrada de variáveis como valor da dívida, tempo de atraso, histórico de pagamento, perfil de risco, ticket médio e recorrência da inadimplência, as ferramentas analíticas permitem a criação de modelos de segmentação que classificam os clientes de acordo com seu potencial de recuperação e grau de risco. De acordo com E10: “Com essas informações conseguimos identificar rapidamente quais clientes têm maior risco e agir de forma antecipada.”

Essa classificação, muitas vezes viabilizada por técnicas como modelos preditivos de propensão à inadimplência, permite que as equipes de cobrança concentrem seus esforços nos casos com maior impacto financeiro e maior probabilidade de retorno, otimizando recursos e aumentando a eficiência operacional. (E6: “Antes gastávamos muito tempo com todos os clientes; hoje conseguimos focar onde realmente faz diferença.”)

Além disso, os dashboards interativos permitem o monitoramento em tempo real da evolução dos indicadores de cobrança, possibilitando ajustes imediatos nas estratégias adotadas, conforme o comportamento da carteira. Em linha com o comentário de E3: “A visualização em tempo real mudou totalmente nossa rotina, pois conseguimos adaptar a estratégia sem precisar esperar o fechamento mensal.”

A priorização deixa de ser baseada apenas na senioridade do título (dias em atraso) e passa a considerar múltiplas dimensões, como o perfil comportamental do cliente, o histórico de respostas a negociações anteriores e a sensibilidade a diferentes canais de cobrança. Como resultado, a atuação da equipe torna-se mais direcionada e eficaz, reduzindo o ciclo de recuperação, melhorando os índices de recebimento e contribuindo diretamente para a melhoria do fluxo de caixa da organização. De acordo com E1: “Hoje sabemos exatamente quais clientes devem ser priorizados, e isso reduziu significativamente o tempo médio de recuperação.”

A adoção de ferramentas de *Data Analytics* gerou mudanças significativas no fluxo de trabalho da equipe responsável pela gestão de crédito e cobrança, refletindo tanto em aspectos operacionais quanto estratégicos. Antes da implementação dessas ferramentas, grande parte do tempo da equipe era dedicada a atividades manuais e repetitivas, como a consolidação de dados de diferentes fontes, elaboração de planilhas e geração de relatórios estáticos. Conforme destacou E11, “antes gastávamos horas consolidando dados e, mesmo assim, havia risco de erros; hoje conseguimos direcionar esse tempo para análises que realmente agregam valor”.

Com a automatização proporcionada por plataformas como Power BI e Databricks, essas tarefas passaram a ser executadas de forma integrada e contínua, reduzindo retrabalho, eliminando erros operacionais e liberando tempo para análises mais aprofundadas e tomadas de decisão estratégicas. Nesse sentido, E2 complementa: “a automatização trouxe uma agilidade que não tínhamos, principalmente para identificar rapidamente variações críticas no fluxo de caixa”.

Houve também uma mudança cultural importante: os profissionais passaram a ter maior autonomia na interpretação dos dados, uma vez que os dashboards analíticos tornaram a informação mais acessível, visual e interativa. Isso fomentou uma cultura orientada por dados (*data-driven*), na qual as decisões são embasadas em evidências concretas, e não mais apenas na intuição ou na experiência empírica. O fluxo de trabalho tornou-se mais dinâmico e colaborativo, com maior integração entre os setores financeiro, comercial e de cobrança, que passaram a compartilhar indicadores em tempo real e alinhar ações com base nas mesmas informações. De acordo com E8, “o maior ganho foi a transparência: todos os setores têm acesso às mesmas informações, o que facilitou o alinhamento e reduziu retrabalhos”.

Adicionalmente, os ciclos de análise e resposta foram significativamente encurtados, permitindo maior agilidade na identificação de problemas e implementação de soluções. A padronização dos relatórios e a centralização das informações também facilitaram o acompanhamento de metas e desempenho individual, promovendo maior controle.

Por outro lado, embora as ferramentas de *Data Analytics* tenham proporcionado avanços significativos na agilidade e na precisão da análise e priorização de clientes em processos de crédito e cobrança, ainda existem situações em que o tempo demandado continua sendo um desafio. Conforme ressaltado por E7, “mesmo com dashboards atualizados em tempo real, quando lidamos com clientes novos ou com baixa recorrência de operações, a ferramenta sozinha não é capaz de nos dar segurança total para a tomada de decisão”. Um dos principais fatores que contribuem para essa limitação é o caso de clientes sem histórico suficiente, ainda dependemos de avaliação humana para complementar a análise. Segundo E7, “nesses casos, a experiência do analista e o contato direto com informações qualitativas acabam sendo indispensáveis, porque o modelo analítico não possui dados suficientes para gerar previsões confiáveis”.

5.4.2.1 Melhorias na segmentação de clientes

A segmentação de clientes, especialmente no contexto do crédito e da cobrança, tornou-se significativamente mais eficiente com o uso de ferramentas de *Data Analytics*, que possibilitam a análise integrada de múltiplas variáveis. Entre os critérios mais relevantes fornecidos por essas ferramentas, destacam-se inicialmente os dados financeiros e comportamentais, como histórico de pagamento, valor médio de compras, prazo médio de recebimento (PMR), e frequência de atrasos. Essas informações permitem identificar padrões que diferenciam clientes adimplentes, inadimplentes eventuais e devedores crônicos, facilitando a definição de estratégias personalizadas para cada perfil. Como ressaltou E6, “essa diferenciação entre perfis foi fundamental, porque antes tratávamos todos os inadimplentes de forma semelhante, o que comprometia a eficiência da cobrança”.

Outro critério essencial é a capacidade de risco projetada, obtida a partir de modelos de score internos que utilizam variáveis como volume de crédito concedido, limite utilizado, recorrência de renegociações e comportamento de compras ao longo do tempo. Essa análise é complementada por indicadores de inadimplência setorial ou regional, que ajudam a contextualizar

o risco individual de cada cliente em relação ao mercado no qual está inserido. Nesse sentido, E11 destacou: “quando passamos a comparar o risco individual com a média do setor, conseguimos ajustar limites de crédito de forma muito mais assertiva”. A combinação desses fatores permite maior precisão na classificação e priorização das ações de cobrança, otimizando recursos e aumentando as chances de recuperação.

A análise realizada sustenta a Proposição 2, ao demonstrar que a utilização de ferramentas de *Data Analytics* resultou em melhorias expressivas na eficiência dos processos de crédito e cobrança. A automação da consolidação de dados e a disponibilização de dashboards dinâmicos reduziram o tempo médio de análise de crédito, permitindo maior agilidade e produtividade das equipes. A visualização em tempo real dos indicadores, mencionada por E3, e a transparência das informações compartilhadas entre setores, ressaltada por E8, também contribuíram para a redução de retrabalhos e para a maior integração organizacional. Assim, os resultados corroboram a proposição ao indicar que o uso de *Data Analytics* não apenas otimizou recursos e reduziu o tempo gasto em tarefas operacionais, mas também tornou o processo de cobrança mais direcionado, colaborativo e eficaz, refletindo em melhorias concretas de eficiência.

5.4.3 Identificação de padrões com vistas à redução de inadimplência e à melhoria do fluxo de caixa nas organizações

O uso de ferramentas de *Data Analytics* trouxe melhorias perceptíveis e concretas na gestão do fluxo de caixa, ao permitir uma visão mais precisa, dinâmica e preditiva das entradas e saídas financeiras. Com a integração de dados históricos de recebíveis, comportamento de inadimplência e prazos médios de pagamento, tornou-se possível projetar o fluxo de caixa com maior confiabilidade, reduzindo incertezas e melhorando o planejamento financeiro. Como observou E4, “a previsibilidade aumentou muito; agora conseguimos ajustar o planejamento financeiro antes que o problema aconteça”. Um exemplo prático dessa evolução é a possibilidade de identificar, com antecedência, períodos de maior concentração de inadimplência, o que permite ações proativas de cobrança e ajustes nas políticas de concessão de crédito. Segundo E9, “essa antecipação é fundamental para negociar com clientes estratégicos e evitar quedas bruscas na liquidez”.

Segundo E5, “antes tínhamos que trabalhar com estimativas muito amplas; hoje conseguimos prever com dias de antecedência onde estarão os maiores riscos de descasamento de caixa”. E2 acrescenta: “isso nos deu condições de negociar com clientes estratégicos antes mesmo do atraso, preservando o relacionamento e garantindo entrada de recursos”.

Desde a implementação de ferramentas de *Data Analytics*, observou-se uma redução progressiva e sustentada nos índices de inadimplência da empresa, reflexo direto da maior capacidade analítica aplicada à gestão de crédito e cobrança. Como destacou E3, “a tecnologia nos permitiu antecipar os riscos, o que antes só identificávamos após o atraso”. Antes da adoção dessas tecnologias, as estratégias de concessão de crédito e cobrança eram baseadas em critérios padronizados e análises retrospectivas, o que dificultava a identificação precoce de clientes com potencial de inadimplência. Com a utilização do Power BI, tornou-se possível integrar dados de diferentes fontes e aplicar modelos preditivos, que identificam padrões de comportamento e classificam os clientes por nível de risco. E8 reforça: “os modelos preditivos trouxeram uma mudança radical na forma como gerenciamos o risco, aumentando nossa assertividade”. Essa abordagem mais precisa permitiu ajustes na política de crédito, com concessões mais seguras e alinhadas ao perfil financeiro de cada cliente.

Além disso, ao utilizar dashboards interativos, a área financeira passou a monitorar em tempo real os valores a vencer e vencidos, segmentados por cliente, região ou faixa de risco, o que possibilita decisões mais rápidas e alinhadas com a realidade operacional. De acordo com E11, “o acompanhamento em tempo real mudou nossa rotina; conseguimos agir quase imediatamente quando percebemos algum risco”. De acordo com E8, “a visualização segmentada dos recebíveis nos permite agir de forma seletiva e mais eficiente, sem dispersar recursos da equipe de cobrança”.

Outro exemplo prático da contribuição do *Data Analytics* para o fluxo de caixa está na definição mais assertiva dos limites de crédito concedidos aos clientes. Antes da adoção de ferramentas analíticas, a definição de crédito era feita com base em critérios padronizados, muitas vezes pouco sensíveis ao perfil real do cliente e ao risco que ele representa. Com a utilização de algoritmos preditivos e painéis interativos, tornou-se possível considerar uma gama mais ampla de variáveis, como índice de inadimplência por segmento, comportamento de compra, tempo médio de pagamento, score de crédito interno e volume histórico de compras. E7 destacou: “essa mudança reduziu significativamente os casos de exposição desnecessária e deu mais segurança à equipe”. Nesse ponto, E10 observa: “a revisão dos limites de crédito com base em dados concretos reduziu bastante os casos de exposição desnecessária e melhorou o equilíbrio do fluxo de caixa”.

Com isso, a concessão de crédito se torna mais segura, evitando a exposição excessiva da empresa a riscos que poderiam comprometer o fluxo de caixa. Ao mesmo tempo, os clientes com bom histórico são incentivados a aumentar suas compras, o que contribui para o crescimento das receitas com menor risco de perdas. Nesse ponto, E2 acrescenta: “os clientes bons passaram a ter mais crédito e isso aumentou nosso faturamento sem elevar o risco”.

Os períodos de baixa liquidez representam um dos maiores desafios para a sustentabilidade financeira das organizações, especialmente em contextos de elevada volatilidade econômica ou sazonalidade no faturamento. Durante esses momentos, caracterizados pela redução nas entradas de recursos e pelo acúmulo de obrigações financeiras a vencer, torna-se essencial adotar práticas de gestão mais rigorosas e proativas para preservar a capacidade de pagamento da empresa. Nesses cenários, o uso de ferramentas de *Data Analytics* tem se mostrado particularmente relevante, ao permitir o monitoramento contínuo dos indicadores de liquidez e a identificação antecipada de possíveis desequilíbrios entre receitas e despesas. Conforme relatou E12, “em meses críticos, conseguimos replanejar pagamentos e antecipar recebíveis porque o sistema nos alertou com antecedência sobre a queda na liquidez”.

Além disso, o monitoramento em tempo real de indicadores como o prazo médio de recebimento (PMR) e taxa de recuperação possibilitou a atuação preventiva da equipe de cobrança, priorizando casos com maior risco de perda e aumentando a eficácia das ações de recuperação. Conforme relatou E11, “hoje conseguimos focar nos casos críticos rapidamente, o que tem aumentado nossa taxa de recuperação”. Como consequência, a inadimplência deixou de ser tratada de forma reativa e passou a ser gerenciada com foco na prevenção. De acordo com E13: “Houve uma redução consistente nas faixas de atraso superior a 90 dias e um aumento no índice de recuperação nos primeiros 30 dias após o vencimento, refletindo uma gestão mais eficiente e orientada por dados”. Dessa forma, o uso de *Data Analytics* tem contribuído de forma decisiva para o controle da inadimplência, fortalecendo o fluxo de caixa e a estabilidade financeira da organização. E5 complementa: “os resultados positivos mostram como o investimento em análise de dados é fundamental para a saúde financeira da empresa”.

Entre os indicadores mais relevantes, destaca-se inicialmente a taxa de inadimplência, medida tradicionalmente pela proporção de clientes ou valores vencidos em relação à carteira total. A redução desse índice após a adoção de ferramentas analíticas é um dos principais sinais de que a segmentação e o acompanhamento sistemático dos riscos passaram a ser mais eficazes. Como observou E2, “notamos que, após a implementação, a inadimplência passou a ser monitorada com mais rigor, o que resultou em ações preventivas eficazes”.

Outro indicador fundamental é o índice de recuperação de crédito, que expressa o percentual de valores inadimplentes efetivamente recuperados dentro de um determinado período. O *Data Analytics* tem permitido maior assertividade nas estratégias de cobrança ao identificar perfis comportamentais, histórico de pagamento e capacidade preditiva de regularização. E7 destacou que “compreender o perfil do cliente possibilitou direcionar esforços para quem realmente precisava de renegociação, otimizando recursos”.

Isso facilita, por exemplo, a aplicação de diferentes abordagens por perfil (como renegociação para inadimplentes eventuais e ações legais para inadimplentes crônicos), elevando o

índice de recuperação. Conforme ressaltou E10, “a segmentação baseada em dados tornou as ações jurídicas mais focadas, evitando custos desnecessários”.

Embora o uso de ferramentas de *Data Analytics* represente um avanço significativo na gestão do crédito e da cobrança, a obtenção de resultados consistentes pode ser comprometida por diversos fatores estruturais, técnicos e humanos. Esses entraves, muitas vezes subestimados, devem ser considerados como parte do contexto organizacional e operacional, pois impactam diretamente a capacidade de transformar dados em decisões efetivas. Como apontou E4, “sem um ambiente organizacional alinhado e processos claros, os dados podem acabar sendo subutilizados”.

Outro fator está relacionado à maturidade analítica da organização. Empresas em estágios iniciais de adoção ainda enfrentam dificuldades para interpretar corretamente os outputs das ferramentas, aplicar as informações de maneira estratégica ou mesmo confiar nas recomendações automatizadas. E9 comentou que “a falta de familiaridade com os modelos e dashboards gera receio e, muitas vezes, resistência à adoção plena das ferramentas”.

Muitas vezes, as equipes não possuem formação técnica suficiente em análise de dados ou estatística, o que exige investimentos em capacitação contínua ou a inclusão de profissionais especializados, como cientistas de dados ou analistas de BI. Segundo E2, “o investimento em treinamento e contratação de especialistas é fundamental para extrair todo o potencial das ferramentas analíticas”.

5.5. Avaliação conjunta das proposições de pesquisa

A análise dos três tópicos investigados revela que a utilização de ferramentas de *Data Analytics* tem exercido um papel transformador na gestão do crédito e da cobrança, corroborando integralmente as proposições centrais da pesquisa. A Proposição 1 (P1) foi confirmada pela percepção unânime dos entrevistados quanto ao aprimoramento da capacidade dos gestores financeiros em tomar decisões estratégicas mais assertivas e fundamentadas em dados históricos e preditivos, substituindo decisões intuitivas por análises estruturadas e atualizadas em tempo real (E1, E2, E12). Em relação à Proposição 2 (P2), as ferramentas proporcionaram ganhos significativos de eficiência operacional, reduzindo drasticamente o tempo de análise de crédito e otimizando a priorização dos clientes na cobrança, com foco nos perfis de maior risco e potencial de recuperação, o que também favoreceu uma cultura organizacional mais orientada por dados (E9, E10, E11). Por fim, a Proposição 3 (P3) foi validada pelas melhorias concretas observadas na redução da inadimplência e no aprimoramento do fluxo de caixa, mediante a identificação precoce de padrões de risco, definição mais segura dos limites de crédito e monitoramento dinâmico de indicadores financeiros essenciais, mesmo reconhecendo desafios relacionados à qualidade dos dados e à maturidade analítica das equipes (E3, E4, E7, E8). Em suma, as respostas qualitativas evidenciam que o uso integrado e estratégico de *Data Analytics* não só potencializa a eficiência e a precisão das decisões, como também fortalece a sustentabilidade financeira das organizações.

A análise conduzida confirma a Proposição 3, ao demonstrar que a utilização de ferramentas de *Data Analytics* na gestão do crédito e da cobrança tem sido decisiva para a identificação de padrões capazes de reduzir a inadimplência e melhorar o fluxo de caixa. A integração de dados históricos, comportamentais e preditivos possibilitou antecipar riscos e atuar preventivamente, como ressaltaram E3 e E8, que destacaram a mudança de uma abordagem reativa para uma gestão proativa e orientada por dados. Os dashboards interativos e modelos preditivos facilitaram o monitoramento em tempo real de indicadores críticos, permitindo ajustes imediatos nas estratégias e ampliando o índice de recuperação em prazos menores. Ademais, a definição mais assertiva dos limites de crédito, evidenciada nos depoimentos de E7 e E2, contribuiu para reduzir a exposição desnecessária e, simultaneamente, incentivar o crescimento de clientes com bom histórico, fortalecendo a liquidez organizacional. Ainda que desafios relacionados à maturidade analítica e à qualidade dos dados persistam, os resultados convergem para a validação de que o uso de *Data Analytics* é um fator-chave na prevenção da inadimplência e na sustentação do fluxo de caixa, consolidando-se como um diferencial estratégico na gestão financeira.

De forma integrada, os resultados confirmam as três proposições desta pesquisa. A Proposição 1 foi validada pelo fortalecimento da capacidade estratégica dos gestores, que passaram a basear suas decisões em análises estruturadas e atualizadas em tempo real, substituindo práticas intuitivas. A Proposição 2 demonstrou-se consistente na medida em que as ferramentas de *Data Analytics* trouxeram ganhos expressivos de eficiência, reduzindo significativamente o tempo dedicado a tarefas operacionais e possibilitando maior foco em ações de alto valor agregado. Por fim, a Proposição 3 foi confirmada pela capacidade das ferramentas em identificar padrões de comportamento e antecipar riscos, contribuindo para a redução da inadimplência e o fortalecimento do fluxo de caixa. Assim, evidencia-se que a adoção do *Data Analytics* constitui um fator estratégico central para a gestão financeira contemporânea, promovendo decisões mais assertivas, eficientes e orientadas para a sustentabilidade organizacional. A Tabela 32 concentra as proposições, indicadores, comentários e impactos percebidos.

Tabela 32

Resumo das proposições, indicadores, comentários e impactos percebidos

Proposição	Indicador	Comentário	Impacto Percebido	Entrevistados Referência
P1	Capacidade de decisão estratégica	Substituição de decisões intuitivas por análises baseadas em dados históricos e monitoramento em tempo real	Decisões mais assertivas, ágeis e alinhadas ao perfil financeiro, melhor alocação de recursos	E1, E2, E12
P2	Eficiência na análise e priorização	Redução do tempo de análise de crédito de minutos para segundos; priorização focada em clientes de maior risco	Aumento da produtividade, maior agilidade na resposta e otimização dos esforços da equipe	E9, E10, E11
P2	Fluxo de trabalho e cultura	Automatização e dashboards interativos promovendo maior autonomia e integração entre setores	Ambiente mais colaborativo e orientado por dados, redução de retrabalho e maior transparência	E2, E8
P3	Redução da inadimplência	Uso de modelos preditivos e monitoramento em tempo real para identificar e atuar precocemente nos riscos	Diminuição consistente da inadimplência, aumento da recuperação e fortalecimento do fluxo de caixa	E3, E7, E8, E11
P3	Melhoria no fluxo de caixa	Previsibilidade aprimorada e segmentação para concessão segura de crédito	Planejamento financeiro mais confiável e decisões rápidas que preservam a liquidez da empresa	E4, E5, E7
P3	Desafios na aplicação	Limitações relacionadas à qualidade dos dados, maturidade analítica e resistência cultural	Necessidade de capacitação contínua e investimentos para maximizar o uso das ferramentas	E4, E9, E2

Fonte: Dados da pesquisa

6. CONCLUSÃO

Este estudo teve como objetivo investigar o impacto do uso de ferramentas de *Data Analytics* no setor específico da área de crédito e cobrança de uma distribuidora de acumuladores elétricos com abrangência nacional, com base na comparação de dados históricos e pós-implantação destas ferramentas. Para tal foi empregada a metodologia da pesquisa-ação procurando realizar uma análise dos achados empíricos mediante proposições de pesquisa estabelecidas. A coleta de dados desenvolveu-se pela triangulação de dados, buscando se basear em várias fontes de evidências, conduzindo a uma convergência de: (i) levantamento de documentos; (ii) observação participante, (iii) entrevistas semiestruturadas e entrevista estruturada.

Foi providenciada inicialmente uma análise dos dados quantitativos provenientes da abordagem quase-experimental de amostras de colaboradores que compuseram os grupos pré e pós da adoção das ferramentas de *Data Analytics*. As técnicas estatísticas avançadas empregadas,

que incluíram desde a análise descritiva de dados até a aplicação de testes inferenciais, como o teste t para amostras independentes, a Análise de Variância (ANOVA), e a modelagem de regressão linear, permitiram a revelação de nuances cruciais sobre a eficácia dessas políticas operacionais.

Os resultados que emergem desta análise não são apenas estatisticamente significativos, mas também reveladores, oferecendo contribuições tanto para o arcabouço teórico do campo acadêmico quanto para a práxis da gestão no cenário nacional, particularmente no que tange à aplicação de ferramentas de *data analytics* e inteligência de dados na gestão de crédito e cobrança.

A demonstração de uma causalidade ou, no mínimo, de uma forte associação estatística entre a implementação do Painel em Power BI para classificação de risco, a utilização do algoritmo próprio de limite de crédito e o treinamento intensivo em *data analytics* e a subsequente diminuição dos níveis de endividamento não solvido é de suma importância. Tal constatação representa a validação empírica da proposição central da pesquisa, que postulava a eficácia do conjunto de medidas em questão. A análise comparativa, um pilar metodológico desta dissertação, entre o grupo que foi submetido à intervenção (doravante denominado grupo pós intervenção) e o grupo que não recebeu a intervenção (denominado grupo pré intervenção) revelou diferenças de desempenho que são, sob qualquer ótica estatística, marcantes e inegáveis, evidenciando o poder transformador de uma gestão de crédito e cobrança baseada em dados e ferramentas de *data analytics*.

A disparidade observada entre os dois grupos não foi trivial, mas sim de uma magnitude que exige atenção, e que reflete o impacto direto da intervenção. O grupo que passou a utilizar o Painel em Power BI, o algoritmo de limite de crédito e recebeu capacitação específica, reduziu a inadimplência em 17,79%, enquanto o grupo de controle permaneceu praticamente estável, com variação de apenas -0,14%, evidenciando de forma clara a efetividade da intervenção.

A solidez desta diferença foi submetida a um teste estatístico rigoroso, que valida a eficácia da intervenção. A aplicação do teste t para amostras independentes, uma das ferramentas mais confiáveis para comparar médias entre dois grupos, confirmou a significância estatística altamente relevante ($p < 0,0001$). Este valor de 'p', extremamente baixo, indica que a probabilidade de que a diferença observada entre as médias dos grupos tenha ocorrido meramente por acaso é inferior a 0,01%. Em termos práticos, é virtualmente impossível que essa disparidade tenha sido fruto de flutuações aleatórias, solidificando a inferência de que a intervenção, com seus componentes de *Power BI* e algoritmo, foi o fator determinante para a redução da inadimplência.

A análise de dados estatísticos foi complementada por entrevistas estruturadas e semi-estruturadas que fortalece o argumento de que a adoção de ferramentas de *Data Analytics* na gestão de crédito e cobrança representa não apenas uma inovação técnica, mas uma mudança cultural e operacional com alto impacto positivo percebido pelos profissionais envolvidos. Ao se aprofundar na análise dos dados qualitativos revela-se que a utilização de ferramentas de *Data Analytics* tem exercido um papel transformador na gestão do crédito e da cobrança, corroborando integralmente as proposições centrais da pesquisa.

A Proposição 1 (P1) foi confirmada pela percepção unânime dos entrevistados quanto ao aprimoramento da capacidade dos gestores financeiros em tomar decisões estratégicas mais assertivas e fundamentadas em dados históricos e preditivos, substituindo decisões intuitivas por análises estruturadas e atualizadas em tempo real. O impacto mais significativo observado foi na qualidade da tomada de decisão. Como destacaram vários entrevistados, a capacidade de analisar padrões históricos, comportamentos de pagamento e tendências em tempo real permitiu substituir gradativamente as decisões subjetivas por análises objetivas e fundamentadas. Um gestor resumiu bem essa evolução: "Antes, trabalhávamos com planilhas estáticas e impressões pessoais. Hoje, nossos dashboards nos mostram não apenas o que aconteceu, mas o que provavelmente vai acontecer".

Em relação à Proposição 2 (P2), as ferramentas proporcionaram ganhos significativos de eficiência operacional, reduzindo drasticamente o tempo de análise de crédito e otimizando a priorização dos clientes na cobrança, com foco nos perfis de maior risco e potencial de recuperação, o que também favoreceu uma cultura organizacional mais orientada por dados. Ou seja, na

operação diária, os ganhos de eficiência foram marcantes. O tempo dedicado à análise de crédito reduziu-se drasticamente - em alguns casos, de horas para minutos. Essa agilidade trouxe um duplo benefício: por um lado, aumentou a produtividade das equipes; por outro, permitiu respostas mais rápidas às demandas do mercado, um fator competitivo crucial no atual ambiente de negócios.

E, por fim, a Proposição 3 (P3) foi validada pelas melhorias concretas observadas na redução da inadimplência e no aprimoramento do fluxo de caixa, mediante a identificação precoce de padrões de risco, definição mais segura dos limites de crédito e monitoramento dinâmico de indicadores financeiros essenciais, mesmo reconhecendo desafios relacionados à qualidade dos dados e à maturidade analítica das equipes. A priorização de clientes na cobrança talvez seja o exemplo mais claro da vantagem competitiva proporcionada pelo *Data Analytics*. Ao identificar padrões e segmentar devedores por perfil de risco e potencial de recuperação, as empresas conseguiram otimizar seus esforços, concentrando-se nos casos mais relevantes e aplicando estratégias diferenciadas para cada segmento. Essa abordagem *data-driven* resultou em melhorias mensuráveis nos índices de inadimplência e recuperação de crédito.

O painel de risco permite uma gestão proativa da carteira de cobrança, direcionando os esforços para os títulos de maior risco, o que otimiza o uso dos recursos e acelera a recuperação de valores. O algoritmo de limite de crédito, por sua vez, atua na prevenção, garantindo que a concessão de crédito seja feita de forma mais criteriosa, minimizando o risco de futuras inadimplências. A sinergia entre prevenção (algoritmo) e remediação (painel de risco) é crucial para o impacto observado. A diminuição do Prazo Médio de Recebimento (PMR), é uma consequência lógica e esperada da utilização do algoritmo próprio de limite de crédito. Ao conceder crédito de forma mais inteligente e com base em dados, a tendência é que o tempo médio para recebimento diminua, pois a probabilidade de atrasos e inadimplência se reduz. O PMR, como indicador que mede o tempo médio necessário para que uma empresa receba o pagamento de suas vendas, é diretamente impactado pela qualidade da concessão de crédito e pela eficiência da cobrança. A integração da ferramenta de limite de crédito com a gestão do PMR é um aspecto fundamental da intervenção e um benefício esperado.

A consistência dos resultados em todas as regiões analisadas, com os devidos ajustes de magnitude, é um forte indicativo de que a política testada, que envolve a aplicação de tecnologia e a capacitação para seu uso, pode ser escalada. A capacidade de demonstrar que uma intervenção é eficaz em diferentes contextos regionais é um argumento poderoso para a sua adoção em nível nacional, garantindo que os benefícios sejam distribuídos de forma mais ampla.

A pesquisa contribui diretamente para uma gestão mais eficiente, estratégica e orientada para resultados, com o objetivo final de promover a estabilidade dos negócios em todo o território nacional, através da adoção inteligente de tecnologia e da capacitação de equipes para a gestão de crédito e cobrança.

6.1 Limitações de Pesquisa

Como é inerente a todo esforço científico, este estudo, apesar de sua robustez metodológica e da significância de seus achados sobre a eficácia de uma intervenção que integra *data analytics*, ferramentas como Power BI e algoritmos de crédito, além de treinamento, possui limitações que precisam ser explicitamente reconhecidas e discutidas.

Em primeiro lugar, destaca-se a qualidade dos dados utilizados pelas organizações. A efetividade das análises financeiras depende fortemente da consistência, confiabilidade e integridade das informações coletadas. Dados incompletos, desatualizados ou inconsistentes podem comprometer a precisão dos indicadores e, conseqüentemente, a tomada de decisão. Essa limitação se agrava em empresas que ainda não possuem processos estruturados de governança de dados, o que reduz o potencial de extração de valor das ferramentas de *Data Analytics*.

Outro aspecto refere-se à maturidade analítica das organizações. Empresas em estágios iniciais de adoção de tecnologias analíticas frequentemente enfrentam dificuldades em alinhar suas práticas de gestão financeira ao uso pleno dos recursos disponíveis. A falta de metodologias

consolidadas, de profissionais qualificados e de integração entre sistemas pode restringir a capacidade de transformar dados em informações estratégicas. Isso sugere que os resultados positivos observados podem não se replicar em contextos organizacionais com menor nível de maturidade tecnológica e analítica.

Por fim, a pesquisa também esbarra em barreiras relacionadas à resistência cultural. A adoção de ferramentas de *Data Analytics* implica mudanças na forma de pensar e agir dos gestores, demandando maior confiança em análises baseadas em evidências e menor dependência da intuição ou da experiência acumulada. Contudo, em muitas organizações, observa-se resistência de profissionais e lideranças em modificar práticas tradicionais, o que pode reduzir a efetividade da utilização dessas ferramentas. Essa barreira cultural torna o processo de transformação digital mais lento e desigual entre diferentes empresas e setores.

Em conjunto, essas limitações evidenciam que a implementação de *Data Analytics* na gestão financeira não depende apenas da disponibilidade tecnológica, mas também de fatores estruturais e humanos, que condicionam a intensidade e a qualidade dos benefícios alcançados.

6.2 Recomendações de Trabalhos Futuros

Primeiramente, sugere-se a realização de estudos que incorporem modelos estatísticos mais sofisticados, visando uma compreensão mais granular do impacto da intervenção e suas interações. A complexidade dos fenômenos sociais e econômicos, especialmente quando se trata de adoção e impacto de tecnologias, muitas vezes demanda abordagens analíticas que transcendem os modelos lineares simples. Modelos como a regressão multinível (também conhecida como modelos hierárquicos ou de efeitos mistos) seriam particularmente úteis. Isso porque a inadimplência e a eficácia das políticas (incluindo o Painel, o Algoritmo e o Treinamento) são fenômenos que operam em múltiplos níveis (e.g., individual do cliente, da equipe local, da região).

A regressão multinível permitiria capturar a influência simultânea de fatores em diferentes níveis e entender como as características regionais ou municipais (nível superior, como infraestrutura tecnológica ou cultura de dados) influenciam a resposta individual (nível inferior, como a adesão ao uso do Painel ou do Algoritmo) à intervenção. Adicionalmente, a aplicação de modelos de equações estruturais (SEM) ou análise de caminhos (path analysis) permitiria examinar relações de causalidade mais complexas, incluindo mediações e moderações no impacto da intervenção. Por exemplo, poderíamos testar hipóteses sobre como o treinamento afeta a proficiência no uso do Power BI, que por sua vez afeta a eficácia do Painel de Risco, que então impacta a inadimplência. Ou como o efeito do algoritmo é moderado pela qualidade dos dados de entrada.

Em segundo lugar, recomenda-se a ampliação da base de dados para incluir variáveis adicionais que, embora não diretamente abordadas no escopo atual, são reconhecidamente relevantes para o fenômeno da inadimplência, para a eficácia das políticas e, crucialmente, para a adoção de tecnologias.

Adicionalmente, seria de extrema relevância a realização de estudos longitudinais, que transcendessem o período de observação relativamente curto desta dissertação. Acompanhar o comportamento do indicador de inadimplência e os efeitos da intervenção ao longo de períodos mais extensos – por exemplo, por vários anos após a implementação da política, do Painel, do Algoritmo e do Treinamento – permitiria avaliar a sustentabilidade dos efeitos observados e identificar possíveis efeitos de longo prazo, tanto positivos quanto negativos. Uma redução imediata da inadimplência é importante, mas a capacidade de a política manter ou aprofundar esses ganhos ao longo do tempo é crucial para sua avaliação de custo-benefício.

REFERÊNCIAS

- Abiteboul, S., Mangalam, A., & Vianu, V. (1995). *Foundations of databases: The logical level*. Addison-Wesley.
- Accenture. (2018). *Redefine banking with artificial intelligence*. Available at https://www.accenture.com/_acnmedia/pdf-68/accenture-redefine-banking.pdf
- Aires, C. S. F., Almeida, G. J., & Silveira, S. O. (2019). *Inteligência artificial na gestão de estoque*. FATEC Guarulhos. Disponível em <http://fateclog.com.br/anais/2019/INTELIG%C3%8ANCIA%20ARTIFICIAL%20NA%20GEST%C3%83O%20DE%20ESTOQUE.pdf>.
- Al Zoubi, M. I. (2023). The significance of effective corporate governance and transformational big data analysis in enhancing firm financial performance. *Journal of Accounting and Finance*, 45(1), 1-15. <https://doi.org/10.53555/jaz.v45i1.3200>
- Allstate. (2018). *Allstate elevates customer service through artificial intelligence*. Available at <https://www.allstatenewsroom.com/news/allstate-elevates-customerservice-through-artificial-intelligence/>
- Almeida, F. C., & Passari, A. F. (2023). Aplicação de redes neurais na previsão de vendas no varejo. *Revista Brasileira de Gestão de Negócios*, 25(2), 234-250
- Alpaydin, E. (2020). *Introduction to Machine Learning (4th ed.)*. MIT Press.
- Al-Sai ZA, Husin MH, Syed-Mohamad SM, Abdin RMS, Damer N, Abualigah L, Gandomi (2022). Explore Data Analytics Applications and Opportunities: A Review. *Data Analytics and Cognitive Computing*; 6(4):157. <https://doi.org/10.3390/bdcc6040157>
- Altman, E. I. (2017). *Corporate Financial Distress & Bankruptcy: Predict and Avoid Bankruptcy, Analyze and Invest in Distressed Debt*. John Wiley & Sons.
- Altman, E. I., Marco, G., & Varetto, F. (1994). Corporate distress diagnosis: Comparisons using linear discriminant analysis and neural networks (the Italian experience). *Journal of Banking & Finance*, 18(3), 505-529.
- Araújo, L., Behr, A. ., & Schiavi, G. S. (2023). Adoção de business analytics na contabilidade. *Revista Contabilidade & Finanças*, 34(93), e1771. <https://doi.org/10.1590/1808-057x20231771.en>

- Assaf Neto, A. (2020). *Estrutura e Análise de Balanços: Um Enfoque Econômico-Financeiro*. Atlas.Gitman, L. J., & Zutter, C. J. *Princípios de Administração Financeira*. Pearson.
- Assis, A. G. de, & Decoster, S. R. A. (2025). Gerenciamento de risco de crédito por meio da utilização de aprendizado de máquina: o caso do Banco BS2. *Revista Catarinense Da Ciência Contábil*, 24, e3526. <https://doi.org/10.16930/2237-766220253526>
- Avelar, E. A., Campos, O. V., Orefici, J. B. P., & Leocádio, V. A. (2025). Previsão de valor corporativo em períodos de crise: uso de algoritmos de aprendizado de máquina em empresas do G20. *Contabilometria - Brazilian Journal of Quantitative Methods Applied to Accounting*, 12(2), 38-54.
- Azevedo, V. M., & Figueira, L. B. (2020). Detecção de Fraude Financeira utilizando Ciência de Dados. Trabalho apresentado na WorkTec 2020. http://www.fatecrp.edu.br/WorkTec/edicoes/2020-1/trabalhos/I-Worktec-Victor_Azevedo.pdf
- Babin, B. J., et al. (2015). *Essentials of Contemporary Management*. Cengage Learning.
- Ballou, R. H. *Gerenciamento da cadeia de suprimentos - Logística empresarial*. (2006) - 5ª ed - São Paulo: Bookman.
- Bank of America. (2019). Erica makes banking easier than ever. Available at <https://promo.bankofamerica.com/erica/>
- Barbiere, Carlo – *BI. Business Intelligence modelagem e tecnologia* – Rio de Janeiro:Axcel Books, 2001. p. 62
- Bardin, L. (2009). *Análise de conteúdo*. Lisboa: Edições 70.
- Bello O.A. (2024) The Role of Data Analytics in Enhancing Financial Inclusion in Emerging Economies, *International Journal of Developing and Emerging Economies*, Vol.11, No.3, pp.90-112
- Beneish, M. D. (1999). Incentives and penalties related to earnings manipulation. *Journal of Accounting and Economics*.
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.

- Bodjov, Y. (2018). Machine learning in risk forecasting and its application in low volatility strategy. Toronto Dominion Bank. Available at https://www.tdaminstitutional.com/tmi/pdfs/machlearn0918_E.pdf
- Brigham, E. F. (2016). *Administração financeira: teoria e prática*. Cengage Learning.
- Brito, E. P. Z., Brito, L. A. L., & Morganti, F. (2009). Inovação e o desempenho empresarial: Lucro ou crescimento? *RAE Eletrônica*, 8(1)
- Brynjolfsson, E., Hitt, L. M., & Kim, H. (2011). Strength in numbers: How does data-driven decision making affect firm performance? *SSRN Electronic Journal*.
- Caliandro, A., & Graham, J. (2020). Studying Instagram Beyond Selfies. *Social Media + Society*, 6(2). <https://doi.org/10.1177/2056305120924779>
- Canhoto, A. I., & Clear, F. (2020). Artificial intelligence and machine learning as business tools: A framework for diagnosing value destruction potential. *Business Horizons*, 63(2), 183e193.
- Capel, H., & Martins, L. M. (2012). A importância do planejamento financeiro no sucesso das empresas. *Revista de Ciências Empresariais*, 13(1), 29-40
- Carr, J. (2013). A simple approach to retail clustering. Wilson Perumal and Company. Available at http://cdn2.hubspot.net/hubfs/2088178/Wilson%20Perumal%20Nov2016%20Theme/PDF%20Link/Vantage_Point_2013_Issue3.pdf
- Chakarverti, M., Sharma, N., & Divivedi, R. (2019). Prediction analysis techniques of data mining: A review. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.3350303>
- Chandran, P. (2018). Disruption in retail: AI, machine learning, and big data. Medium. Available at <https://towardsdatascience.com/disruption-in-retail-ai-machinelearning-big-data-7e9687f69b8f>
- Chase, JP Morgan (2017). Innovations in finance with machine learning, big data, and artificial intelligence: Summary of the latest research and trends. Available at <https://www.jpmorgan.com/global/research/machine-learning>
- Chen, H., Chiang, R. H. & Storey, V. C. (2012). Business Intelligence and Analytics: From Data Analytics to Big Impact. *MIS quarterly*, 36(4), 1165–1188.

- Chen, M., Mao, S., & Liu, Y. (2014). Data Analytics: A survey. *Mobile Networks and Applications*, 19(2), 171-209
- Chodorow, K., & Dirolf, M. (2010). *MongoDB: The Definitive Guide*. O'Reilly Media.
- Codd, E. F. (1970). A Relational Model of Data for Large Shared Data Banks. *Communications of the ACM*, 13(6), 377-387
- Colleoni, J. P. (2019). *Indicadores de Desempenho: um guia completo para Gestão de Performance*.
- Confederação Nacional do Comércio de Bens; Serviços e Turismo (CNC). (2022). *Pesquisa de endividamento e Inadimplência do Consumidor*.
- COSO Report, Internal Control (2013)– Integrated Framework – Executive Summary.
- Cruz, R., & Oliveira, T. (2023). *Análise preditiva financeira: como tomar decisões mais informadas e antecipar problemas*. Equals. <https://equals.com.br/blog/analise-preditiva/>
- Daros, M., & Pinto, N. (2017). Inadimplência no Brasil: Uma Análise das Evidências Empíricas. *Revista de Administração IMED*, 7(1), 208-229. doi:<https://doi.org/10.18256/2237-7956/raimed.v7n1p208-229>
- Dashevsky, E. (2019). Allstate transforms its call centers with Amelia. IPsoft. Available at <https://www.ipsoft.com/2019/03/22/allstate-transforms-its-callcenters-with-amelia/>
- Davenport, T. H. (2006). Competing on analytics. *Harvard business review*, 84(1), 98
- Davenport, T. H. (2014). Data Analytics in big companies. *International Institute for Analytics*, 2(2), 1-21.
- Davenport, T. H. (2014) How strategists use “Data Analytics” to support internal business decisions, *Discovery and production. Strategy and Leadership*, 42(4), 45–50
- Davenport, T. H., & Harris, J. G. (2007). *Competing on analytics: The new science of winning*. Harvard Business Review Press.

- Davenport, T. H., & Patil, D. J. (2012). Data scientist: The sexiest job of the 21st century. *Harvard Business Review*, 90(10), 70-76
- Deloitte (2023). Benefícios e limitações da IA generativa. Recuperado em: <https://www2.deloitte.com/us/en/pages/consulting/articles/generative-ai-for-enterprises.html>.
- Dewasiri, N. J., Dharmarathna, D. G; Choudhary,M., (2024). Leveraging Artificial Intelligence for Enhanced Risk Management in Banking: A Systematic Literature Review. *Artificial Intelligence Enabled Management: An Emerging Economy Perspective*, Chapter 13, 197-213. doi 10.1515/9783111172408013
- Elena Ivona Dumitrescu, Sullivan Hué, Christophe Hurlin, Sessi Tokpavi. (2022) Machine Learning for Credit Scoring: Improving Logistic Regression with Non Linear Decision Tree Effects. *European Journal of Operational Research*, 297 (3), pp.1178-1192.
- Ernst & Young (2023). How digital transformation helped benefit fans and the bottom line. Recuperado de [http:// https://www.ey.com/pt_br/insights/consulting/how-digital-transformation-helped-benefit-fans-and-the-bottom-line](http://https://www.ey.com/pt_br/insights/consulting/how-digital-transformation-helped-benefit-fans-and-the-bottom-line)
- Esteves, G. (2021). *Menos Achismo, Mais Dados*. Editora XYZ.
- Etaati, L. (2019). *Azure Databricks*. In: *Machine Learning with Microsoft Technologies*. Apress, Berkeley, CA. https://doi.org/10.1007/978-1-4842-3658-1_10
- Fávero, Luiz Paulo; Belfiore, Patricia. (2017) *Manual de Análise de Dados* . 1 ed. Editora Elsevier Ltda, Rio de Janeiro, RJ, Brasil.
- Feurer, M.; Hutter, F. Hyperparameter optimization.(2019) In: *Automated machine learning*:. Springer, Cham, 2019. p. 3–33.
- FIA.(2024). *Gestão financeira: conceitos práticas*. Recuperado de <https://www.fia.com.br/gestao-financeira>
- Freitas Junior, J. C. da S., A. C. G., Maçada, Oliveira, M., Brinkhues R. A. (2016) *Data Analytics e gestão do conhecimento: definições e direcionamentos de pesquisa* - Revista Alcance – Eletrônica – vol. 23 – n. 4

- Friedman, A. J., Cosby, A. G., & Boyko, S. (2014). Impact of a school-based nutrition education intervention on dietary intake and behavior in a select population of second-grade students in Scottsdale, Arizona. *Journal of Nutrition Education and Behavior*, 46(6), S99-S100.
- Gaboardi, M. M., & Ferreira, F. M. (2020). A importância da demonstração do fluxo de caixa como ferramenta gerencial. *Revista Gestão, Sustentabilidade e Negócios*, 8(1), 17-35.
<https://www.saofranciscodeassis.edu.br/rgsn/arquivos/RGSN15/artigos/A-importancia-da-demonstracao-do-fluxo-de-caixa.GABOARDI-B.FERREIRA-MM.SILVA-FM.p.17-35.pdf>
- Gandomi, A., & Haider, M. (2015). Beyond the hype: Data Analytics concepts, methods, and analytics. *International Journal of Information Management*, 35(2), 137-144.
- Ganesh, C., & Kesavulu Reddy, R. (2022). Overview of the predictive data mining techniques. *International Journal of Computer Sciences and Engineering*, 10(1), 30-36.
<https://doi.org/10.26438/ijcse/v10i1.2836>
- Gartner. (2020). *Data Analytics and Business Intelligence Strategy*, 2020.
- Gartner. (2023). 10 Strategic Data and Analytics Predictions Through 2028. Gartner Research.
<https://www.gartner.com/en/articles/gartner-strategic-data-and-analytics-predictions-through-2028>
- Gibson, C. H. (2019). *Financial reporting and analysis*. Cengage Learning
- Gil, A. C. (2019). *Métodos e Técnicas de Pesquisa Social*. Atlas.
- Gitman, L. J. (2018). *Principles of managerial finance*. Pearson.
- Grant Thornton. (2023). Data analytics agregando valor e eficiência em auditoria interna.
<https://www.grantthornton.com.br/insights/artigos-e-publicacoes/data-analytics-agregando-valor-e-eficiencia-em-auditoria-interna/>
- Gray, G., & Debreceeny, R. S. (2014). The role of data mining in detecting financial fraud. *Journal of Financial Crime*.
- Gupta, Manjul , George, Joey. (2016). Toward the Development of a Data Analytics Capability. *Information & Management*. doi:53. 10.1016/j.im.2016.07.004.

- Gupta, Manoj & Chandra, Pravin. (2020). A comprehensive survey of data mining. *International Journal of Information Technology*. 1-15. 10.1007/s41870-020-00427-7.
- Gupta, S., & Mehta, S. K. (2021). Data mining-based financial statement fraud detection: Systematic literature review and meta-analysis to estimate data sample mapping of fraudulent companies against non-fraudulent companies. *Global Business Review*, 1–24.
- Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2010). *Análise multivariada*. Bookman.
- Kuhn, M. (2015). *Programação e predição com R*. Bookman.
- Han, J., Kamber, M., & Pei, J. (2011). *Data mining: Concepts and techniques*. Morgan Kaufmann.
- Hasan, M., Hoque, A., & Le, T. (2023). Big data-driven banking operations: Opportunities, challenges, and data security perspectives. *FinTech*, 2(3), 484–509. <https://doi.org/10.3390/fintech2030028>
- Hastie, T., Tibshirani, R., & Friedman, J. (2017). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction* (2nd ed.). Springer.
- Hilbert, M., & López, P. (2011). The World's Technological Capacity to Store, Communicate, and Compute Information. *Science*, 332(6025), 60-65.
- Hopkin, P. (2017). *Fundamentals of Risk Management: Understanding, Evaluating and Implementing Effective Risk Management*. Kogan Page Publishers.
- Huang, Y., Qiu, X., Yang, J., & Tian, H. (2010). The association rule mining technology in marketing decision-making and its application in logistics enterprises. In *Proceedings* (pp. 252-257). https://doi.org/10.1142/9789814295062_0040
- Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and Practice* (3rd ed.). OTexts. Disponível em <https://otexts.com/fpp3/>
- Ilumeo. (2024). *Ciência de Dados e Planejamento Financeiro*. <https://ilumeo.com.br/categorias/2021-03-02-ciencia-de-dados-e-planejamento-financeiro/>
- ING. (2018). Using AI to assess credit risk. Available at <https://www.ing.com/Newsroom/All-news/Using-AI-to-assess-credit-risk.htm>

- Jahan, Roshan & Javed, Nashra & Sheikh, Fahad. (2016). Cluster Analysis Techniques in Data Mining: A Review.
- Johnson, R. T., & Montgomery, D. C. (2010). Designing experiments for nonlinear models -An introduction. *Quality and Reliability Engineering International*, 26(5).<https://doi.org/10.1002/qre.1063>
- Junqueira, G. (2018). Gestão Financeira no varejo: como tornar eficiente? *Infovarejo* <https://www.infovarejo.com.br/gesta-financeira-no-varejo>
- Kache, Florian; Seuring, Stefan. (2017) Challenges and opportunities of digital information at the intersection of Data Analytics and supply chain management. *International Journal of Operations & Production Management*, v. 37, n. 1, p. 10-36, 2017. doi: 10.1108/IJOPM-02-2015-0078.
- Kelleher, J. D., Mac Namee, B., & D'Arcy, A. (2020). *Fundamentals of Machine Learning for Predictive Data Analytics: Algorithms, Worked Examples, and Case Studies*. MIT Press.
- Kerlinger, F. N. (1980). *Metodologia da pesquisa em ciências sociais: um tratamento conceitual*. São Paulo, SP: EPU/EDUSP.
- Kim, K. J., & Lee, H. (2017). The influence of Data Analytics capabilities on organizational performance: A resource-based view. *Journal of Organizational Computing and Electronic Commerce*, 27(3), 238-257.
- Kotsiantis, S., Kanellopoulos, D., & Pintelas, P. E. (2006). Data mining: A knowledge discovery approach. *Advances in Artificial Intelligence*.
- Kuhn, M. (2015). *Programação e predição com R*. Bookman.
- Kumar, V., & Verma, S. (2012). Data mining techniques for fraud detection. *International Journal of Computer Applications*.
- Laney, D. (2001). *3D Data Management: Controlling Data Volume, Velocity, and Variety*. META Group.

- Lassance, L. C. B. K., & Ternoski, S. (2021). Score ia cresol: Utilizando inteligência artificial para estimar viabilidade de crédito. *Revista Aproximação*, 3(06). Recuperado de: <https://revistas.unicentro.br/index.php/aproximacao/article/view/6923>.
- Lazer, D., Kennedy, R., King, G., & Vespignani, A. (2014). The parable of Google Flu: traps in Data Analytics analysis. *Science*, 343(6176), 1203-1205.
- LeCun, Y., et al. (2015). "Deep Learning." *Nature*, 521(7553), 436-444.
- Liu, H., Huang, S., Wang, P., & Li, Z. (2021). A review of data mining methods in financial markets. *Data Science in Finance and Economics*, 1(4), 362-392. <https://doi.org/10.3934/DSFE.2021020>
- Lorena, A. C. de Carvalho, A. C. P. L. F. (2003) Introdução às Máquinas de Vetores Suporte (Support Vector Machines). Relatório Técnico nº 192 do Instituto de Ciências Matemáticas e de Computação da USP.
- Lucena, L.P. Apostila de gestão agroindustrial. UFMT, Rondonópolis, MT. (2019). DOI:10.13140/RG.2.2.24490.16325/1
- Lukka, K., & Vinnari, E. (2017). Combining actor-network theory with interventionist research: present state and future potential. *Accounting, Auditing and Accountability Journal*, 30(3). <https://doi.org/10.1108/AAAJ-08-2015-2176>
- Luo, X., Kizito, E., & Huang, L. (2018). The impact of Data Analytics on firm performance: A literature review. *Information Technology & People*, 31(4), 914-946
- Manyika, J., Chui, M., Brown, B., Bughin, J., Dobbs, R., Roxburgh, C., & Byers, A. H. (2011). *Data Analytics: The next frontier for innovation, competition, and productivity*. McKinsey Global Institute.
- McAfee, A., & Brynjolfsson, E. (2012). *Data Analytics: The management revolution*. Harvard Business Review, 90(10), 60-68.
- McKinney, W. (2020). *Python para Análise de Dados*. O'Reilly Media.
- Medeiro, Y. M. D., & Souza, J. C. (2021). Aplicação de novas tecnologias na gestão de estoques. ID on line Revista de Psicologia, 15(55). <https://doi.org/10.14295/idonline.v15i55.3031>

- Medeiros, M. M., Maçada, A. C. G., & Hoppen, N. (2021). O papel da administração e análise de Data Analytics como habilitadoras da gestão do desempenho corporativo. *Revista de Administração Mackenzie*, 22(6), 1–32. doi:10.1590/1678-6971/eRAMD210063
- Mhlanga, D. (2024). The role of big data in financial technology toward financial inclusion. *Frontiers in Big Data*, 7. <https://doi.org/10.3389/fdata.2024.1184444>
- Microsoft. (2021). O que é o Power BI? Recuperado de <https://powerbi.microsoft.com/pt-br/what-is-power-bi/>
- Minayo, M. C. de S. (2008). *O desafio do conhecimento*. 11 ed. São Paulo: Hucitec.
- Mitchell, T. *Machine Learning* (1997). McGraw Hill
- Nazareth, Noella & Reddy, Y.V.. (2023). Financial applications of machine learning: A literature review. *Expert Systems with Applications*. 219. 119640. 10.1016/j.eswa.2023.119640.
- Ngai, E.W.T., Hu, Y., Wong, Y.H., Chen, Y., & Sun, X. (2011). The application of data mining techniques in financial fraud detection: A review. *Decision Support Systems*.
- Oliveira, JPS, Santos, S. de J., & Decoster, SRA (2022). Aceitação e uso de ferramentas de Big Data & Analytics pelos Profissionais de Controladoria, Finanças e FP&A.
- Oncioiu I, Bunget OC, Türkeş MC, Căpuşneanu S, Topor DI, Tamaş AS, Rakoş I-S, Hint MŞ. (2019). The Impact of Data Analytics on Company Performance in Supply Chain Management. *Sustainability*. 2019; 11(18):4864. doi:10.3390/su11184864
- Pagar.me. (2024). Como funciona a gestão financeira nas empresas?. Recuperado de <https://www.pagar.me/blog/gestao-financeira-nas-empresas>
- Phua, C., Lee, V., Smith-McLallen, A., & Gayler, R. (2010). A survey of data mining techniques for social network analysis. *Journal of Computer Science and Technology*.
- Provost, F., & Fawcett, T. (2013). *Data Science para Negócios: O que você precisa saber sobre data mining e machine learning*. O'Reilly Media.

- Rahman , M.A ., & Afroz , N .(2013). Data mining techniques in financial fraud detection: A review. *International Journal of Computer Applications*.
- Roberts, M., & Taylor, D. (2022). *How Analytics Is Changing Finance*. Knowledge at Wharton. Disponível em: <https://knowledge.wharton.upenn.edu/article/how-analytics-is-changing-finance>
- Sanders, N. R. (2016). *How to Use Data Analytics to Drive Your Supply Chain*. *California Management Review*, 58(3), 26–48. doi:10.1525/cmr.2016.58.3.26.
- Santos, F. S., & Marques, F. M. (2019). *Gestão do Capital de Giro*. Saraiva Educação.
- Santos, L. P., & Oliveira, L. A. (2021). *O impacto no desempenho financeiro das empresas com a implementação de capacidades de Big Data Analytics: uma visão comparativa*. Dissertação de Mestrado, Fundação Getulio Vargas. <https://repositorio.fgv.br/handle/10438/30868>
- Satler, Caluio Carlos. (2024). *A influência da tecnologia na gestão financeira: o uso da inteligência artificial*. Doi: 10.69849/revistaft/th102410242302
- Saunders, A., & Cornett, M. M. (2018). *Financial Institutions Management: A Risk Management Approach*. McGraw-Hill Education.
- Scott, A. O., Amajuoyi, P., & Adeusi, K. B. (2024). *Advanced risk management solutions for mitigating credit risk in financial operations*. *Magna Scientia Advanced Research and Reviews*, 11(1), 212–223.
- Sebrae. (2023). *Gestão financeira para pequenas empresas: o que você precisa saber*. Recuperado de <https://www.sebrae.com.br/sites/PortalSebrae/cursosonline/gestao-financeira>
- Sell, Isair. (2005) *Utilização da regressão linear como ferramenta de decisão na gestão de custos*. In: CONGRESSO BRASILEIRO DE CUSTOS, 12., 2005, Florianópolis. Anais. Florianópolis: Associação Brasileira de Custos, 2005
- Serasa Experian. (2024). *Big data e análise de dados na transformação digital: quais são os principais impactos?*. Serasa Experian. <https://www.serasaexperian.com.br/conteudos/inovacao-e-tecnologia/big-data-e-analise-de-dados/>

- Setty, Kumar, and Bakhshi, Rohit. (2013). "What Is Data Analytics and What Does It Have to Do With IT Audit?" *ISACA Journal*, vol.5, pp 23-15.
- Shen, W., Lin, Y., & Zhang, Y. (2015). Forecasting stock indices with back propagation neural network. *Procedia Computer Science*, 55, 683-692.
- Silva, A. M., & Cavalcante, F. (2018). *Análise Financeira de Crédito*. Atlas.
- Sivarajah, U., Kamal, M. M., Irani, Z., & Weerakkody, V. (2017). Critical analysis of Data Analytics challenges and analytical methods. *Journal of Business Research*, 70, 263-286.
- Spathis, L. (2002). Detecting false financial statements using published data: Some evidence from Greece. *Managerial Auditing Journal*.
- Suryanarayana, P., & Kumar, R. (2023). Machine learning in the financial industry: A bibliometric approach to understanding its impact. *International Journal of Financial Studies*, 11(1), 1-20. <https://doi.org/10.1080/23311886.2023.2276609>
- Tan, P. N. (2018). *Introduction to Data Mining*. Pearson.
- Toaldo, Alessandro; Vallim Filho, Arnaldo R. A.; Oyadomari, José C. T. & Mendonça Neto, Octavio R. (2024). Validação de modelos de machine learning por experimentos estatísticos de campo. *Revista Gestão & Tecnologia*, vol. 24, n^o 5, p. 125-153
- Turban, E., & Volonino, L. (2017). *Information technology for management: digital strategies for insight, action, and sustainable performance*. John Wiley & Sons.
- UCEFF. (2024). Big Data Analytics: o que é, importância e benefícios!. Recuperado de <https://blog.uceff.edu.br/big-data-analytics/>
- Usmani, S. (2018). *Beginning Power BI: A Practical Guide to Self-Service Data Analytics with Excel 2016 and Power BI Desktop*.
- Vashi, Priyankaben. (2023). A Comprehensive Review on Association Rule Mining and its Algorithms: Apriori, FP Growth, and SS-FIM. *International Journal for Research in Applied Science and Engineering Technology*. 11. 2507-2512. 10.22214/ijraset.2023.54067.

- Vavilapalli, V. K., (2013). Apache Hadoop YARN: Yet Another Resource Negotiator. Proceedings of the 4th Annual Symposium on Cloud Computing, 5-10.
- Vergara, S. C. (2015). Projetos e Relatórios de Pesquisa em Administração. Atlas.
- Viana de Souza, F. J., de Macedo Farias, M. das V., Backes Steppan, A. I., & da Silva, M. C. (2011). A Educação Financeira e a sua Influência na Tomada de Decisões. Revista De Contabilidade Da UFBA, 5(2), 81–95. <https://doi.org/10.9771/rcufba.v5i2.5137>
- Voitto. (2024). Gestão financeira: conceitos e práticas essenciais para o sucesso empresarial. Recuperado de <https://www.voitto.com.br/gestao-financeira>
- Waller, Matthew A.; Fawcett, Stanley E. (2013). Data science, predictive analytics, and Data Analytics: a revolution that will transform supply chain design and management. Journal of Business Logistics, v. 34, n.2, p. 77-84, Mar. 2013. doi:10.1111/jbl.12010.
- Wamba, S. F., Akter, S., Edwards, A., Chopin, G., & Gnanzou, D. (2015). How 'Data Analytics' can make big impact: Findings from a systematic review and a longitudinal case study. International Journal of Production Economics, 165, 234-246. Disponível em <https://ideas.repec.org/a/eee/proeco/v165y2015icp234-246.html>
- Ward, J. S., & Barker, A. (2013). Undefined by data: A survey of Data Analytics definitions. arXiv preprint arXiv:1309.5821.
- Xu, Lida Li Zeng, Zhongzhi Shi, Qing He & Maoguang Wang. Research on business intelligence in enterprise computing environment. In: 2007 IEEE International Conference on Systems, Man and Cybernetics. 2007. 2007 IEEE International Conference on Systems, Man and Cybernetics, Montreal, Que., 2007, pp. 3270-3275, doi: 10.1109/ICSMC.2007.4413870. Yamanishi, K., Takeuchi, I., Williams, G., & Milne, P. (2004). On-line unsupervised outlier detection using finite mixtures with discounting learning algorithms. Data Mining and Knowledge Discovery.
- Yin, R. K. (2001) Estudo de caso: planejamento e métodos. 2.ed. Porto Alegre: Bookman, 2001
- Zaharia, M., (2016). "Apache Spark: A Unified Engine for Data Analytics Processing." Communications of the ACM.
- Zanella, C., Vieira, V., Barichello, R., & Rodrigues, M. P. (2016). Previsão de demanda: um estudo de caso em uma agroindústria de carnes do oeste catarinense. Revista Gestão Da Produção Operações E Sistemas, 11(1), 45. <https://doi.org/10.15675/gepros.v11i1.1310>

Zhang , G ., & Zhou , J .(2004). Data mining for financial fraud detection: A review. Journal of Financial Crime.

Zhou , L ., & Kapoor , K .(2011). Financial fraud detection using data mining techniques: A survey. International Journal of Computer Applications.

Zhu, X. (2009). "Semi-Supervised Learning Literature Survey." Technical Report, University of Wisconsin-Madison

Zöller, M., Huber, M. F. (2021) Benchmark and Survey of Automated Machine Learning Frameworks. Journal of Artificial Intelligence Research 70: 409-472.
<https://arxiv.org/pdf/1904.12054>

Zoubi, A. (2023). O impacto positivo de Data Analytics na governança corporativa. Brides Soluções. <https://bridsolucoes.com.br/2023/02/07/governanca-corporativa-baseada-em-dados-e-sua-importancia-dentro-das-empresas/>

GLOSSÁRIO

Algoritmo: Conjunto de regras ou instruções passo a passo usadas para resolver um problema ou realizar uma tarefa específica.

Análise de Sentimento: Técnica de NLP usada para determinar a atitude ou emoção expressa em um pedaço de texto, como positivo, negativo ou neutro.

Análise Preditiva: Uso de dados, algoritmos estatísticos e técnicas de machine learning para identificar a probabilidade de resultados futuros com base em dados históricos.

ARIMA (*Auto Regressive Integrated Moving Average*): É um modelo estatístico usado para análise e previsão de séries temporais. Ele combina três componentes: autoregressão (AR), integração (I) e média móvel (MA). O modelo ARIMA é amplamente utilizado em econometria e análise de dados para prever valores futuros com base em dados históricos.

Auditoria: Processo de exame e verificação das demonstrações financeiras de uma empresa para garantir sua precisão e conformidade com as normas contábeis.

Big Data: Conjunto de dados tão volumoso e complexo que não pode ser analisado usando sistemas de gestão de base de dados ou programas de software tradicionais.

Blockchain: Tecnologia de registro distribuído que permite a criação de um livro-razão digital seguro e imutável, usado principalmente para registrar transações de criptomoedas.

Business Intelligence (BI): Conjunto de processos, tecnologias e ferramentas usadas para transformar dados brutos em informações significativas e úteis para fins de análise de negócios.

Computação em Nuvem: Modelo de entrega de serviços de computação, como servidores, armazenamento, bancos de dados, rede, software e análise, pela internet ("a nuvem").

Conformidade Regulamentar: Adesão às leis, regulamentos e normas aplicáveis às operações financeiras de uma empresa.

Dashboards Interativos: Ferramentas de visualização de dados que permitem aos usuários interagir com os dados, explorar diferentes perspectivas e obter informações em tempo real.

Data Analytics (DA): Conjunto de técnicas e ferramentas utilizadas para analisar grandes volumes de dados para a tomada de decisões estratégicas.

Data Lake: Repositório centralizado que permite armazenar todos os dados estruturados e não estruturados em qualquer escala.

Data Warehouse: Sistema de armazenamento de dados projetado para permitir a análise e o relatório de grandes volumes de dados de diferentes fontes

ETL (Extração, Transformação e Carga): ETL é um processo de integração de dados que envolve a extração de dados de várias fontes, a transformação desses dados em um formato adequado para análise e a carga dos dados transformados em um sistema de destino, como um data warehouse. Este processo é essencial para a preparação de dados para análise e relatórios.

Fluxo de Caixa: Movimento de entrada e saída de dinheiro em uma empresa, essencial para avaliar a liquidez e a saúde financeira da organização.

Fraude Financeira: Atividade ilegal que envolve a manipulação de informações financeiras para obter ganhos indevidos.

Governança Corporativa: Conjunto de práticas e políticas adotadas por uma empresa para garantir a transparência, a responsabilidade e a equidade em suas operações.

Hadoop: É uma plataforma de software de código aberto usada para o armazenamento e processamento distribuído de grandes conjuntos de dados. Ele utiliza um modelo de programação chamado MapReduce e um sistema de arquivos distribuído (HDFS) para gerenciar dados em clusters de computadores.

Inadimplência: Falta de pagamento de uma dívida no prazo estipulado.

Inclusão Financeira: Acesso a serviços financeiros por indivíduos e empresas que anteriormente eram excluídos do sistema financeiro formal.

Indicadores de Desempenho: Métricas utilizadas para avaliar a eficiência e a eficácia das operações financeiras e administrativas de uma empresa.

Inteligência Artificial (IA): Campo da ciência da computação que se concentra na criação de sistemas capazes de realizar tarefas que normalmente requerem inteligência humana, como reconhecimento de fala, tomada de decisão e tradução de idiomas.

Internet das Coisas (IoT): Rede de dispositivos físicos, veículos, eletrodomésticos e outros itens incorporados com eletrônica, software, sensores e conectividade que permitem a esses objetos coletar e trocar dados.

Machine Learning: Subcampo da inteligência artificial que envolve o desenvolvimento de algoritmos que permitem que os computadores aprendam a partir de dados e façam previsões ou decisões sem serem explicitamente programados para isso.

Mineração de Dados: Processo de explorar grandes conjuntos de dados para descobrir padrões ocultos e informações valiosas.

Modelagem Estatística: Processo de criação de modelos matemáticos que representam a relação entre diferentes variáveis para prever resultados futuros.

NoSQL: Refere-se a uma classe de sistemas de gerenciamento de banco de dados que não utilizam o modelo relacional tradicional. Eles são projetados para lidar com grandes volumes de dados não estruturados ou semi-estruturados e oferecem flexibilidade na modelagem de dados.

OLAP (Processamento Analítico Online): É uma abordagem para responder rapidamente a consultas analíticas complexas. Ele permite a análise multidimensional de grandes volumes de dados, facilitando a visualização e exploração de dados em diferentes perspectivas. OLAP é amplamente utilizado em aplicações de business intelligence.

Processamento de Linguagem Natural (NLP): Subcampo da inteligência artificial que se concentra na interação entre computadores e humanos usando linguagem natural.

RDBMS (Sistema de Gerenciamento de Banco de Dados Relacional): Um RDBMS é um tipo de sistema de gerenciamento de banco de dados que armazena dados em tabelas que podem ser relacionadas entre si. Ele utiliza a linguagem SQL (Structured Query Language) para gerenciar e consultar dados.

Redes Neurais: Modelos computacionais inspirados no cérebro humano, usados em machine learning para reconhecer padrões complexos e fazer previsões.

RFID (Identificação por Radiofrequência): RFID é uma tecnologia que utiliza ondas de rádio para identificar e rastrear automaticamente objetos. Um sistema RFID consiste em um transponder (etiqueta RFID) e um leitor RFID. As etiquetas RFID podem ser anexadas a produtos, animais ou pessoas para facilitar a identificação e o rastreamento.

Robotic Process Automation (RPA): Tecnologia que usa software para automatizar tarefas repetitivas e baseadas em regras que normalmente são realizadas por humanos.

Transformação Digital: Integração de tecnologias digitais em todas as áreas de uma empresa, resultando em mudanças fundamentais na forma como a empresa opera e entrega valor aos clientes.

Visualização de Dados: Técnica de apresentação de dados em formatos gráficos, como gráficos e dashboards, para facilitar a interpretação e a tomada de decisões.