

Um Estudo de Caso de Análise de Dados para Recuperação de Crédito

Gabriel Gonchoroski de Souza¹, Leandro Rosniak Tibola¹

¹Instituto Federal de Educação, Ciência e Tecnologia Farroupilha (IFFar)
Frederico Westphalen – RS – Brasil

gabriel.2022015522@aluno.iffar.edu.br,
leandro.tibola@iffarroupilha.edu.br

Abstract. *Credit recovery is essential for the financial sustainability of organizations dealing with credit default. This paper presents a case study of data analysis applied to historical records from a credit recovery office, aiming to identify temporal and regional patterns related to payment behavior. Data cleaning, transformation, and exploratory analysis were performed using Python for data processing and Power BI for interactive visualization. The results highlight specific months and regions with higher concentrations of recovered amounts, as well as variations in the number of payers and the average payment per person, providing analytical support for managerial decision-making.*

Resumo. *A recuperação de crédito é essencial para a sustentabilidade financeira de organizações que lidam com a inadimplência. Este trabalho apresenta um estudo de caso de análise de dados aplicado a registros históricos de um escritório de recuperação de crédito, com o objetivo de identificar padrões temporais e regionais relacionados ao comportamento dos pagamentos. Foram empregadas técnicas de limpeza, transformação e análise exploratória dos dados, utilizando Python para o tratamento das informações e Power BI para a visualização interativa. Os resultados evidenciam meses e localidades com maior concentração de valores recuperados, bem como variações na quantidade de pessoas que efetuaram pagamento e no ticket médio por pessoa, fornecendo subsídios analíticos para a tomada de decisão gerencial.*

1. Introdução

A recuperação de crédito é um fator crucial para a saúde financeira e a sustentabilidade de organizações em diversos setores. Nos últimos anos, o cenário de inadimplência no Brasil tem apresentado crescimento significativo, conforme apontado pelo Mapa de Inadimplência do Serasa Experian (2025), revelando um panorama desafiador para instituições que dependem da regularização de dívidas. Diante desse contexto, torna-se evidente que abordagens tradicionais de cobrança frequentemente se mostram pouco eficientes, consumindo tempo e recursos sem garantir o retorno esperado.

Este trabalho surge da necessidade prática de otimizar os processos de cobrança, mediante o uso de análise de dados. O uso de técnicas de tratamento e exploração de dados possibilita identificar padrões temporais e regionais no comportamento de pagamento dos devedores, informação que pode subsidiar decisões operacionais mais assertivas. Além disso, a integração de ferramentas como Python (para tratamento e

preparação dos dados) e Power BI (para construção de visualizações interativas) oferece um ambiente prático para transformar volumes de dados brutos em insumos acionáveis para gestores e equipes de recuperação.

O objetivo deste trabalho é, através de um estudo de caso, identificar, por meio da análise de dados históricos fornecidos por um escritório especializado em recuperação de crédito, os períodos e as regiões com maior potencial de sucesso nas cobranças, visando otimizar a alocação de esforços e recursos. Para isso, o estudo concentrou-se na coleta e tratamento dos registros referentes aos anos de 2022, 2023 e 2024, na análise exploratória destinada à identificação de padrões de pagamento e na construção de visualizações analíticas (mapas de calor, painéis e gráficos) que facilitem a interpretação e a utilização prática dos resultados.

No escopo deste trabalho, foram adotadas três etapas principais: (i) tratamento e padronização dos dados em Python, incluindo anonimização, correção de inconsistências, preenchimento e remoção de duplicidades; (ii) análise exploratória das variáveis temporais e geográficas para detecção de tendências relevantes; e (iii) implementação de visualizações interativas no Power BI, projetadas para apoiar a tomada de decisão por profissionais do escritório. O estudo limita-se aos registros disponibilizados pelo escritório para os anos mencionados e não incluiu validação externa junto ao time operacional, por restrições temporais.

Este artigo está organizado da seguinte forma: a Seção 2 apresenta o referencial teórico que fundamenta o estudo; a Seção 3 descreve em detalhes a metodologia adotada no tratamento e na análise dos dados; a Seção 4 apresenta os resultados obtidos e sua discussão; e, por fim, a Seção 5 reúne as conclusões e sugestões para trabalhos futuros.

2. Referencial Teórico

2.1. Recuperação de Crédito

A recuperação de crédito é um componente essencial para garantir a sustentabilidade financeira de instituições públicas e privadas, abrangendo setores como bancos, cooperativas, empresas varejistas e prestadoras de serviços. Seu propósito vai além da simples regularização de valores em atraso, contribuindo diretamente para a redução de riscos, manutenção da liquidez e continuidade operacional das organizações. Nunes (2013) define a recuperação de crédito como um conjunto estruturado de métodos estratégicos orientados à reversão de perdas, atuando de forma preventiva e corretiva. O autor destaca ainda que políticas bem definidas, aliadas ao uso de tecnologias adequadas, exercem papel fundamental para a eficiência dessa atividade.

O cenário de inadimplência no Brasil reforça a relevância do tema. Em março de 2025, o país registrou 75,7 milhões de brasileiros inadimplentes, segundo o Mapa de Inadimplência do Serasa Experian, evidenciando a dimensão do problema e seu impacto na economia nacional. A alta taxa de inadimplência afeta diretamente a concessão de crédito e os fluxos financeiros das organizações, exigindo estratégias cada vez mais eficazes e baseadas em evidências.

Nesse contexto, técnicas de análise de dados e aprendizado de máquina têm ganhado destaque como ferramentas capazes de aprimorar a tomada de decisão na

recuperação de crédito. Forti (2018), em estudo conduzido na FGV, demonstrou que algoritmos como Random Forest, Support Vector Machine e Gradient Boosting, quando aplicados a dados reais de operações de cobrança, podem prever com maior precisão a probabilidade de regularização das dívidas. Esses modelos permitem a priorização de esforços, o direcionamento estratégico da equipe e a alocação inteligente de recursos, ampliando a taxa de recuperação e reduzindo custos operacionais. Assim, o uso de dados históricos consolidou-se como abordagem promissora para a segmentação de perfis de inadimplentes e para o desenvolvimento de estratégias de cobrança mais assertivas e personalizadas.

2.2. Análise de Dados no Apoio à Tomada de Decisão

A análise de dados integrada a ferramentas de *Business Intelligence* (BI) consolida-se como um recurso estratégico para a tomada de decisão nas organizações. Segundo Araújo (2012), o BI possibilita o monitoramento do ambiente corporativo por meio da integração de diferentes fontes de dados, transformando informações brutas em conhecimento estruturado e relevante para os gestores. Essa capacidade de consolidar, organizar e interpretar grandes volumes de dados contribui diretamente para decisões mais rápidas, eficientes e orientadas por evidências.

Nesse mesmo sentido, Fernandes Júnior e Pinto (2018) demonstraram, por meio de um estudo de caso da Webmotors, como a aplicação prática de técnicas de *Big Data Analytics* pode impulsionar processos decisórios corporativos. A reestruturação da arquitetura de dados da empresa, aliada à adoção de ferramentas analíticas, permitiu a extração de informações estratégicas sobre o comportamento e as preferências dos usuários, resultando na melhoria da experiência do cliente e no aprimoramento das operações internas. Esses avanços foram viabilizados pela capacidade de analisar grandes conjuntos de dados de maneira sistemática e orientada a metas organizacionais.

O exemplo evidencia que a análise de dados não se limita a contextos de alta escala tecnológica, mas pode ser aplicada também em operações financeiras, como os processos de recuperação de crédito. Nesse caso, a identificação de padrões de inadimplência, comportamentos recorrentes de clientes e previsões de recuperação pode apoiar significativamente a definição de estratégias de cobrança mais eficazes, alinhadas a cenários reais e baseadas em evidências quantitativas.

2.3. Processo de Análise de Dados

A etapa de coleta de dados envolve a obtenção de informações provenientes de diferentes fontes, internas ou externas à organização. Essas bases costumam apresentar duplicidades, inconsistências ou lacunas, exigindo um processo cuidadoso de tratamento para assegurar sua utilização adequada na análise. Segundo Ferreira (2020), o tratamento dos dados deve ser conduzido de maneira estruturada, permitindo que a base original permaneça íntegra e disponível para outros estudos.

O autor destaca que problemas comuns em bancos de dados empresariais incluem erros ortográficos, variações de formato e ausência de informações, o que reforça a necessidade de técnicas de padronização, remoção de duplicidades e preenchimento ou exclusão de campos nulos. Essas etapas são essenciais para evitar distorções nas análises e aumentar a confiabilidade dos resultados.

A identificação de padrões no conjunto de dados constitui etapa fundamental para a extração de informações relevantes. Vieira (2021) enfatiza que a análise exploratória permite descobrir tendências e agrupamentos por meio de categorização e visualização, como demonstrado em seu estudo sobre atendimentos de saúde. Ferreira (2020) complementa que ferramentas como o Power BI auxiliam nesse processo ao oferecer recursos para detecção de anomalias, duplicidades e distribuições relevantes, facilitando a interpretação dos dados.

2.4. Ferramentas e Tecnologias Empregadas

2.4.1. Python e suas bibliotecas

A linguagem Python destaca-se como uma das mais utilizadas em projetos de análise de dados devido à sua sintaxe simples, ampla documentação e extensa comunidade de suporte. Conforme McKinney (2018), Python é uma linguagem interpretada que se destaca pela legibilidade e pela forte integração com bibliotecas voltadas a tarefas analíticas e científicas, sendo aplicada tanto em prototipação quanto em soluções de produção. Além disso, oferece suporte a múltiplos paradigmas de programação, tais como o imperativo, funcional e orientado a objetos (PYTHON SOFTWARE FOUNDATION, 2024).

No contexto da análise de dados, o Python dispõe de um ecossistema maduro de bibliotecas especializadas. Entre elas, destaca-se a Pandas, empregada neste estudo para o tratamento de dados tabulares, oferecendo recursos para limpeza, padronização, manipulação de datas e criação de variáveis derivadas. Essa biblioteca permite manipular grandes volumes de informações de forma eficiente, possibilitando a realização das etapas de preparação e exploração necessárias à análise desenvolvida neste trabalho.

2.4.2. Power BI: vantagens para análise visual e tomada de decisão

O Power BI é uma ferramenta de *Business Intelligence* desenvolvida pela Microsoft, amplamente utilizada para transformar grandes volumes de dados em visualizações interativas. Conforme Microsoft (2024a), a plataforma permite a conexão com múltiplas fontes, como arquivos Excel, bancos SQL e serviços em nuvem, oferece também recursos de modelagem e construção de *dashboards* dinâmicos. A biblioteca de visuais certificados do *AppSource* possibilita personalização segura das visualizações, enquanto expressões DAX (Data Analysis Expressions) e recursos de linguagem natural tornam o ambiente acessível mesmo para usuários com pouca experiência técnica (MICROSOFT, 2024b).

Ferreira (2020) destaca, ainda, que a ferramenta possibilita a execução de etapas de extração, transformação e carga de dados, características do processo de ETL (Extract, Transform, Load), permitindo a preparação das informações diretamente no ambiente analítico, sem a necessidade de processos externos. Ressalta-se, entretanto, que o ETL constitui apenas uma das estratégias de manipulação de dados, coexistindo com abordagens como o ELT (Extract, Load, Transform), mais comuns em arquiteturas baseadas em *data lakes* e grandes volumes de dados. No contexto deste trabalho, o uso do Power BI insere-se em uma abordagem de ETL voltada à análise exploratória e ao apoio à tomada de decisão.

3. Metodologia

O trabalho caracterizou-se como um estudo de caso, voltado à identificação de padrões temporais e regionais na recuperação de crédito. Os dados foram fornecidos por um escritório especializado em cobranças e consistiam em um arquivo único no formato Excel, contendo registros referentes aos anos de 2022, 2023 e 2024. Todas as informações pessoais foram previamente tratadas por meio de pseudonimização, com a substituição de identificadores diretos por códigos, sendo a tabela de correspondência mantida sob controle do escritório e não disponibilizada para fins acadêmicos, garantindo conformidade com a Lei Geral de Proteção de Dados Pessoais (LGPD).

Os **dados originais incluíam as seguintes colunas**: Data, Conta, Descrição, Processo, Favorecido, Adverso, Adverso - Ordem de Serviço, Plano de Conta, Conciliado, Valor (com sinal), Parcela da série, Valor, Data da última modificação (sistema), Negociador - Contas a receber/pagar (descrição), Data do Acordo - Contas a receber/pagar (descrição), Honorários Contratuais - Contas a receber/pagar (descrição), Agência do Processo, Valor Bruto, Honorários Sucumbenciais - Contas a receber/pagar (descrição), Centro de Custos. A estrutura apresentava inconsistências comuns em bases operacionais, como variações de escrita, valores nulos e informações redundantes. Por se tratarem de dados sensíveis, os dados brutos não foram apresentados de forma visual neste trabalho, sendo descrita apenas sua estrutura original.

Após a etapa inicial de compreensão da estrutura da base, foi realizada a seleção das colunas relevantes ao objetivo analítico do estudo. Foram removidas as colunas que não contribuíam diretamente para a análise temporal, regional ou financeira da recuperação de crédito, bem como aquelas associadas a controles internos do sistema ou metadados operacionais. Nesse processo, **foram excluídas as colunas** Plano de Conta, Data da última modificação (sistema), Negociador – Contas a receber/pagar (descrição) e Centro de Custos, por não agregarem informações relevantes à identificação de padrões de recuperação. As demais colunas foram mantidas por apresentarem relação direta com os valores recuperados, a identificação dos processos, o período das transações e a localização das cobranças, constituindo a base final utilizada nas análises exploratórias e na construção dos dashboards.

Adicionalmente, foi elaborada uma planilha de apoio com o objetivo de identificar corretamente a origem geográfica dos processos analisados. Para isso, foram **criadas as colunas Comarca e Estado**, as quais não estavam presentes de forma padronizada na base original. A extração dessas informações foi realizada por meio de um script desenvolvido em Python, que analisava o número único do processo judicial. A identificação do Estado baseou-se no padrão do número do processo, no qual o segmento “8.21” indica processos oriundos do Estado do Rio Grande do Sul. A partir dessa identificação, os quatro últimos dígitos do número do processo foram utilizados para determinar a comarca correspondente, por meio do cruzamento com informações públicas do Tribunal de Justiça. Esse procedimento permitiu padronizar e enriquecer a base de dados, garantindo maior precisão na análise regional da recuperação de crédito.

O tratamento dos dados foi realizado em Python, com apoio da biblioteca Pandas para leitura, limpeza, padronização e preparação dos dados. Os dados foram carregados com a função `pandas.read_excel()`, e as colunas de datas foram convertidas para o tipo `datetime`. A partir dessas datas, foram extraídas as variáveis derivadas de mês e ano, utilizadas posteriormente nas análises temporais. Linhas duplicadas foram removidas com `drop_duplicates()`, e valores nulos que comprometiam a análise foram excluídos ou corrigidos conforme o contexto. Processos que apresentavam comarcas divergentes ou ausentes foram padronizados com base no número único do processo, garantindo uniformidade na variável regional.

Além disso, valores financeiros foram convertidos para tipos numéricos com tratamento de sinais positivos e negativos, permitindo cálculos consistentes. Em seguida, **as colunas irrelevantes ao objetivo analítico foram descartadas**, reduzindo a base às informações essenciais para construção dos indicadores. O *dataset* resultante foi exportado novamente em formato Excel para integração com o Power BI.

A base de dados original continha 20 colunas. Após as etapas de limpeza, padronização e seleção de atributos, bem como a criação de variáveis analíticas adicionais, **o dataset resultante passou a conter 17 colunas**, refletindo a exclusão de informações não relevantes e a consolidação das variáveis essenciais à análise proposta. O *dataset* final foi então exportado novamente em formato Excel para integração com o Power BI.

No Power BI, além da modelagem e da construção das visualizações, foram utilizadas expressões escritas na linguagem DAX, própria da ferramenta, para a criação de cálculos personalizados sobre os dados carregados. O uso do DAX permite definir medidas dinâmicas que são recalculadas conforme os filtros aplicados nas visualizações, sendo amplamente empregado na construção de indicadores analíticos em ambientes de *Business Intelligence*. Nesse contexto, foram criados os relacionamentos necessários entre as tabelas importadas, embora a maior parte da análise tenha sido conduzida sobre uma tabela já tratada e consolidada. O ambiente foi estruturado para permitir a criação de segmentadores interativos, possibilitando a filtragem por mês, ano, agência e comarca, bem como o desenvolvimento de medidas em DAX para o cálculo de totais e indicadores de desempenho, como valor recuperado, valor devido, percentual recuperado e contagem de processos.

As visualizações foram elaboradas para apoiar a análise exploratória dos padrões identificados. Entre elas, foram construídos um gráfico de barras para comparação temporal, um mapa de bolhas representando a recuperação por região, e tabelas dinâmicas que permitem avaliar detalhadamente os valores recuperados por comarca e período. O foco do desenho das visualizações foi facilitar a interpretação dos resultados por profissionais do escritório, destacando informações relevantes para a tomada de decisão operacional.

Ao final desse processo, obteve-se um conjunto de dados tratados, padronizados e integrados às visualizações interativas, que permitem explorar a distribuição dos pagamentos no tempo e no espaço, bem como identificar tendências e oportunidades identificadas para análise e planejamento na atuação da equipe de recuperação de crédito.

4. Resultados e Discussão

A etapa de análise de dados permitiu construir um conjunto de visualizações interativas no Power BI, desenvolvidas com o objetivo de apoiar a identificação de padrões temporais e regionais na recuperação de crédito. Os *dashboards* integraram informações referentes aos anos de 2022, 2023 e 2024, possibilitando comparações históricas e facilitando o entendimento do comportamento dos pagamentos ao longo do tempo.

4.1. Distribuição Geográfica da Recuperação de Crédito

A primeira visualização consistiu em um mapa de comarcas, no qual o tamanho dos círculos representa o valor total recuperado em cada localidade. Os resultados evidenciaram forte concentração de valores na região de Frederico Westphalen, principal polo de atuação do escritório. Outras comarcas relevantes incluíram Rodeio Bonito, Tenente Portela, Seberi e Constantina, destacando padrões consistentes entre os três anos analisados.

A padronização prévia dos nomes das comarcas no processo de tratamento dos dados foi fundamental para garantir a precisão geográfica da visualização. O mapa permitiu identificar tanto áreas de alto desempenho quanto regiões com baixo volume recuperado, possibilitando futuras análises de distribuição territorial da inadimplência e potenciais oportunidades de atuação. A Figura 1 apresenta a distribuição geográfica.




Figura 1. Distribuição geográfica da recuperação de crédito por comarca (2022–2024)

Fonte: autoria própria

4.2. Desempenho por Comarca

O gráfico de barras apresentou o valor total recuperado por comarca, permitindo identificar rapidamente as localidades com melhor desempenho. O ranking das cinco comarcas com maior valor recuperado foi composto por:

1. Frederico Westphalen
2. Rodeio Bonito
3. Tenente Portela
4. Seberi
5. Constantina

Esse resultado complementou o mapa geográfico ao evidenciar, de forma numérica, a importância de cada região. Além disso, reforçou a relevância das comarcas do Médio e Alto Uruguai para a operação do escritório, mostrando onde os esforços de cobrança historicamente produziram melhores resultados, como visto na Figura 2.

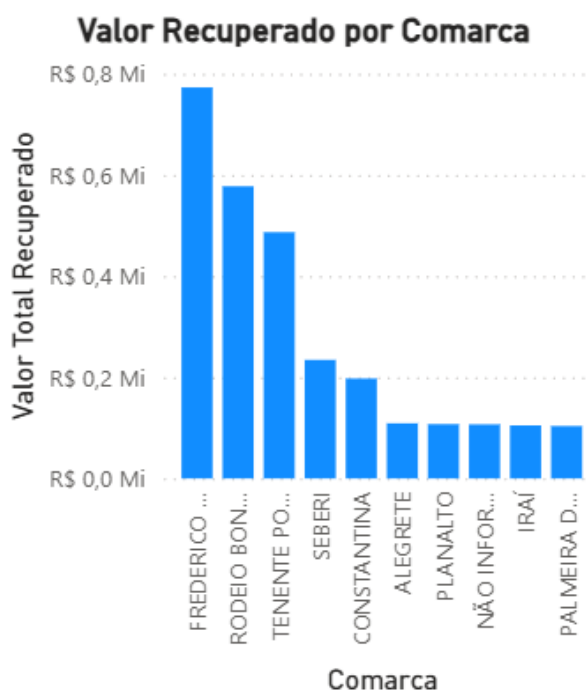


Figura 2. Comarcas com maior valor recuperado

Fonte: autoria própria

4.3. Análise Temporal da Recuperação

O gráfico de linhas permitiu observar a evolução mensal da recuperação nos anos de 2022, 2023 e 2024. De modo geral, os padrões apresentaram comportamento semelhante entre os anos analisados, embora com oscilações mais acentuadas em 2024. Ao longo da série temporal, observam-se variações pontuais em diferentes meses, como

aumentos isolados em maio de 2024, junho e julho de 2023 e setembro de 2022, os quais refletem a variabilidade natural do processo de recuperação de crédito.

Dois comportamentos, entretanto, destacaram-se pela recorrência ao longo dos três anos analisados. O mês de fevereiro apresentou, de forma consistente, um dos menores volumes de recuperação, indicando uma possível sazonalidade negativa, potencialmente associada ao período pós-férias e ao aumento de despesas concentradas no início do ano. Em contrapartida, o mês de outubro concentrou os maiores volumes de recuperação nos três anos, configurando um pico recorrente ao longo da série histórica.

Conforme ilustrado na Figura 3, a aplicação do filtro por mês no *dashboard* permite visualizar de forma integrada o comportamento da recuperação de crédito no mês de outubro, agregando os dados dos três anos analisados. Observa-se que, nesse período, além da concentração dos valores recuperados em determinadas comarcas, o mês de outubro apresenta volume expressivo de recuperação financeira, elevado número de pessoas que efetuaram pagamento e um ticket médio relevante por pessoa, em comparação com outros meses da série histórica.

Essa visualização reforça o caráter recorrente do pico observado em outubro e evidencia o potencial do *dashboard* como ferramenta de apoio à análise temporal e regional da recuperação de crédito, permitindo avaliar simultaneamente o volume recuperado, o alcance dos pagamentos (quantidade de pessoas) e a intensidade média dos valores pagos.

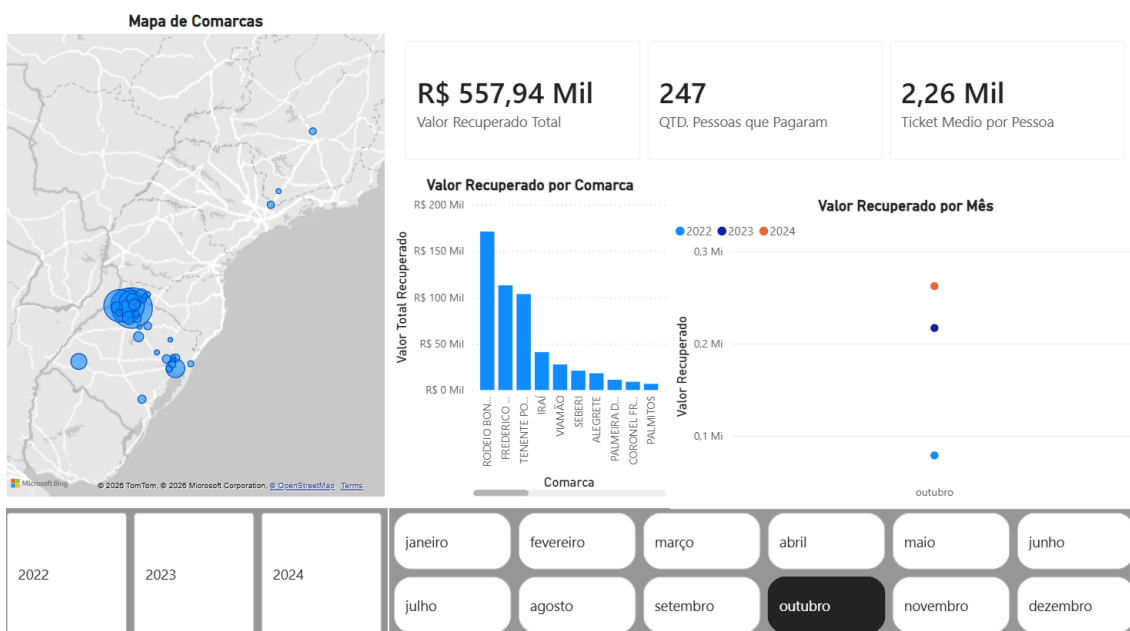


Figura 3. Dashboard de recuperação de crédito para o mês de outubro.

Fonte: autoria própria

A recorrência desse comportamento em outubro diferencia esse mês dos demais picos pontuais observados ao longo da série, sugerindo um período com maior relevância analítica para o planejamento das atividades de cobrança. Esses resultados possibilitam ao escritório avaliar e ajustar suas práticas operacionais, como a definição

de cronogramas de contato, o direcionamento de esforços da equipe e o estabelecimento de metas mensais, com base em padrões históricos identificados nos dados.

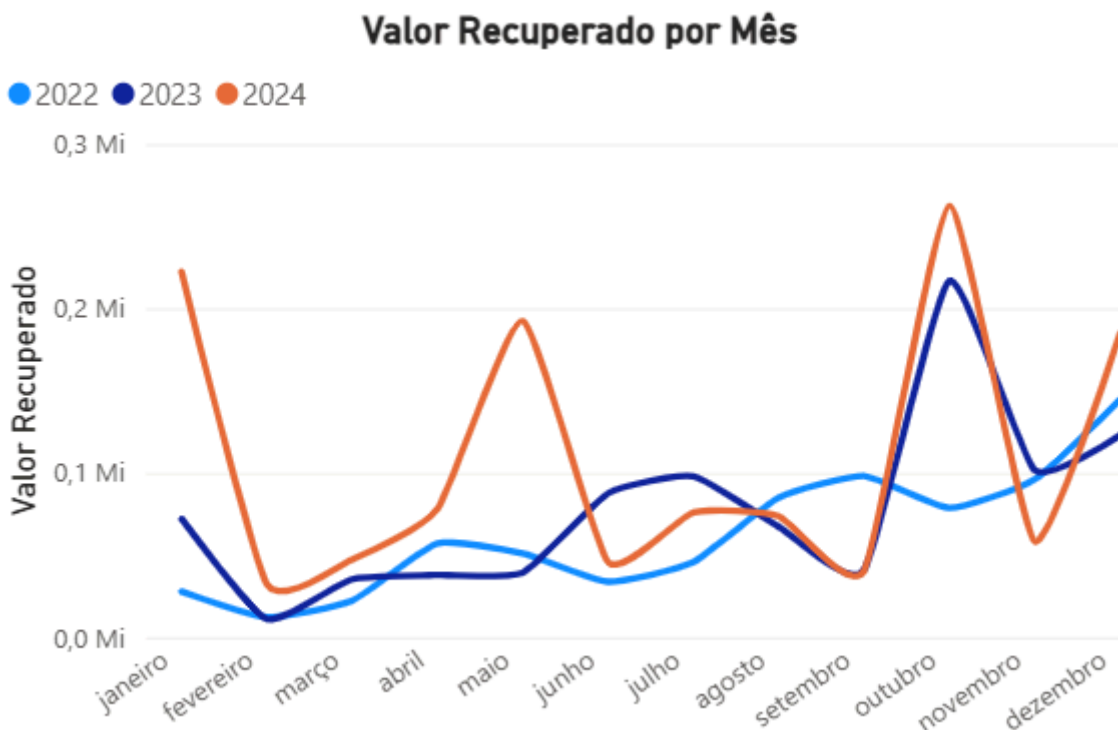


Figura 4. Comportamento mensal do valor recuperado (2022–2024)

Fonte: autoria própria

A análise da quantidade de adversos que efetuaram pagamento ao longo dos meses, apresentada na Figura 5, complementa a avaliação baseada nos valores financeiros recuperados. Observa-se um comportamento sazonal semelhante ao identificado na análise do valor recuperado, com destaque para a redução no número de pagadores no mês de fevereiro e um pico recorrente em outubro. Esse resultado indica que o aumento do volume financeiro recuperado nesse período está associado, em parte, a um maior número de pessoas que realizaram pagamentos, reforçando a importância da análise conjunta de indicadores financeiros e de volume de pagadores na compreensão do processo de recuperação de crédito.

Para aprofundar a análise temporal, além da avaliação dos valores financeiros recuperados, torna-se relevante observar o comportamento do número de adversos que efetivamente realizaram pagamentos ao longo do tempo. Essa perspectiva complementar permite distinguir se os picos observados decorrem do aumento do valor médio pago ou da ampliação do volume de pessoas que aderiram ao pagamento, contribuindo para uma compreensão mais abrangente da dinâmica da recuperação de crédito.



Figura 5. Quantidade de adversos que efetuaram pagamento por mês (2022–2024)

Fonte: autoria própria

4.4. Indicadores Gerais de Recuperação

O painel consolidado apresentou o Indicador-Chave de Desempenho (KPIs)¹ que permitem uma visão sintética e integrada da recuperação de crédito ao longo do período analisado. Entre os principais indicadores, destacam-se o valor total recuperado, que atingiu R\$3,69 milhões nos três anos considerados, a quantidade de pessoas que efetuaram pagamento e o ticket médio por pessoa, calculado a partir da relação entre o valor recuperado e o número de pagadores únicos.

Esses indicadores foram calculados a partir da base de dados tratada em Python e utilizada integralmente na modelagem do Power BI, garantindo consistência entre as etapas de extração, transformação e carregamento dos dados. O uso de medidas dinâmicas possibilita que os KPIs sejam recalculados conforme a aplicação de filtros temporais e regionais, assegurando coerência analítica nas diferentes visualizações.

De forma conjunta, os KPIs fornecem uma visão consolidada da performance do escritório ao longo do período analisado, permitindo avaliar não apenas o volume financeiro recuperado, mas também o alcance das cobranças (quantidade de pessoas) e a intensidade média dos pagamentos (ticket médio). Como métricas descritivas, esses indicadores servem como referência para análises comparativas ao longo do tempo e para o apoio à tomada de decisão gerencial.

¹ Esta sigla corresponde ao termo em inglês “Key Performance Indicator”, os indicadores-chave de desempenho são um apoio importante na definição de estratégias para atingir determinada meta. Fonte: SEBRAE, 2023.

4.5. Benefícios Observados para o Escritório

Os *dashboards* desenvolvidos ofereceram benefícios imediatos ao processo de decisão do escritório, entre eles:

- Identificação das comarcas mais estratégicas, auxiliando na priorização de esforços;
- Detecção de períodos de maior probabilidade de recuperação, com destaque para os meses de outubro;
- Compreensão de sazonalidades negativas, especialmente a queda recorrente em fevereiro;
- Melhoria da capacidade de planejamento, ao permitir análises históricas e regionais simultâneas.

Esses resultados podem contribuir para a melhoria das atividades operacionais, utilizados como apoio a decisões baseadas em evidências e não apenas em percepções empíricas.

5. Conclusão

O presente trabalho estudou o caso de um escritório de recuperação de créditos, analisando os dados históricos referentes aos anos de 2022, 2023 e 2024, com o objetivo de identificar padrões regionais e temporais capazes de apoiar a tomada de decisão em um escritório especializado em cobranças. Por meio do tratamento dos dados em Python e da construção de *dashboards* interativos no Power BI, foi possível estruturar um conjunto de evidências que aprimoram a compreensão do comportamento dos pagamentos ao longo do tempo e do desempenho das diferentes comarcas atendidas.

As análises revelaram forte concentração da recuperação de valores na região de Frederico Westphalen, além de um padrão sazonal recorrente marcado pela baixa recuperação no mês de fevereiro e por picos significativos em outubro. Tais achados permitem ao escritório direcionar esforços de forma mais estratégica, ajustando cronogramas de cobrança, priorização de carteiras e definição de metas mensais com base em evidências concretas.

O *dashboard* desenvolvido demonstrou potencial para subsidiar análises rápidas e objetivas, oferecendo uma visão consolidada do valor total recuperado e permitindo explorar filtros por ano, comarca e outros atributos relevantes. O uso das visualizações facilita a interpretação dos dados, reduz o esforço manual de análise e contribui para a melhoria dos processos internos.

Como trabalhos futuros, recomenda-se a expansão da solução para incluir modelos preditivos de probabilidade de recuperação, a automação completa do fluxo entre Python e Power BI e a integração com sistemas internos do escritório, com vistas à atualização contínua e ao uso operacional da ferramenta. Além disso, a inclusão de variáveis adicionais, como perfil do devedor, tipo de contrato ou tempo de atraso, poderá enriquecer a análise e ampliar o valor gerado para as rotinas de cobrança.

Dessa forma, o estudo demonstrou que o uso estruturado de análise de dados pode apoiar de maneira significativa a eficiência das estratégias de recuperação de crédito, oferecendo uma base objetiva para decisões gerenciais e contribuindo para o aprimoramento dos resultados operacionais da organização.

Referências

- Araújo, J. B.; Azevedo, A. P. (2012). Business Intelligence e sua importância para tomada de decisão: uma revisão bibliográfica. Trabalho de Conclusão de Curso – Universidade Ceuma, São Luís – MA.
- Fernandes Júnior, J. C.; Pinto, G. S. (2018). Big Data Analytics: apresentação do estudo de caso da Webmotors. In: SIMPÓSIO DE TECNOLOGIA – SIMTEC, 5., Taquaritinga. Anais [...]. Taquaritinga: Faculdade de Tecnologia de Taquaritinga.
- Ferreira, G. H. (2020). Limpeza de dados utilizando ferramentas Power BI e Tableau. Trabalho de Conclusão de Curso – FATEC Franca.
- Forti, V. A. (2018). Aplicação de técnicas de aprendizado de máquina na recuperação de crédito: um estudo com dados reais. FGV EAESP, São Paulo. Disponível em: <https://repositorio.fgv.br/bitstreams/2288ba35-fcf1-4422-9bbf-0c5162205136/download>. Acesso em: 12 maio 2025.
- McKinney, W. (2018). Python para análise de dados: tratamento de dados com Pandas, NumPy e IPython. 2. ed. São Paulo: Novatec.
- Microsoft. (2024a). Power BI – Visuais certificados pela Microsoft. Disponível em: <https://www.microsoft.com/pt-br/power-platform/products/power-bi/power-bi-visuals>. Acesso em: 15 maio 2025.
- Microsoft. (2024b). Visão geral do Power BI. Disponível em: <https://learn.microsoft.com/pt-pt/power-bi/fundamentals/power-bi-overview>. Acesso em: 15 maio 2025.
- Nunes, R. E. (2013). A atuação da recuperação de crédito na gestão de risco de crédito: um estudo de caso no Sicredi. Trabalho de Conclusão de Curso – Universidade Federal do Rio Grande do Sul.
- Python Software Foundation. (2024). The Python Language Reference. Disponível em: <https://docs.python.org/3/reference/index.html>. Acesso em: 15 maio 2025.
- SEBRAE (2023). KPIs são estratégicos para medir o desempenho do seu negócio. Disponível em: <https://sebrae.com.br/sites/PortalSebrae/artigos/kpis-sao-estrategicos-para-medir-o-desempenho-do-seu-negocio,56302a20c11a5810VgnVCM1000001b00320aRCRD>. Acesso em 08 de janeiro de 2026.
- Serasa Experian. (2025). Mapa da inadimplência e renegociação de dívidas. São Paulo: Serasa. Disponível em: <https://www.serasa.com.br/limpa-nome-online/blog/mapa-da-inadimplencia-e-renegociacao-de-dividas-no-brasil/>. Acesso em: 12 maio 2025.
- Vieira, F. C. (2021). Análise exploratória de dados: limpeza, manipulação e pré-processamento. Curitiba: UTFPR.