

**BUSINESS INTELLIGENCE APLICADA À ANÁLISE DE MÉTRICAS DE
CUSTOMER SUCCESS EM EMPRESAS SAAS**

Augusto Benate
Graduando em Sistemas de Informação – Uni-FACEF
augusto.bte@proton.me

Prof. Daniel Facciolo Pires
Docente do Departamento de Computação – Uni-FACEF
daniel@facef.br

Resumo

O presente artigo tem como objetivo analisar métricas de *Customer Success* em empresas que atuam no modelo *Software as a Service* (SaaS), utilizando técnicas de *Business Intelligence* (BI) para apoiar a tomada de decisão. Para isso, foi construído um conjunto de dados sintéticos, gerado por meio de código em Python com a biblioteca Faker, e estruturado com base em padrões observados em bases públicas sobre comportamento de clientes. As variáveis contempladas incluem *churn* (taxa de evasão), engajamento, taxa de satisfação do cliente (NPS - Net Promoter Score), tipo de contrato e de serviço, método de pagamento, e valor gerado. A metodologia aplicada envolveu as etapas do ciclo de BI — geração, preparação, análise e visualização — operacionalizadas por meio da ferramenta Looker Studio. Os resultados obtidos evidenciaram fragilidades importantes, como elevada taxa de evasão, baixo engajamento dos clientes e NPS negativo, além da predominância de contratos de curto prazo. A partir dessas análises, foi proposto um plano de ação para o fortalecimento da área de *Customer Success*, incluindo monitoramento contínuo de indicadores, incentivo à contratação de planos mais longos e estratégias de aumento de engajamento. O estudo contribui para a compreensão do papel do BI na gestão estratégica da retenção de clientes em empresas SaaS, reforçando a importância do uso de dados como suporte à tomada de decisões.

Palavras-chave: business intelligence; customer success; saas; métricas de churn; retenção de clientes.

Abstract

This article aims to analyze Customer Success metrics in companies operating under the Software as a Service (SaaS) model, using Business Intelligence (BI) techniques to support decision-making. To achieve this, a synthetic dataset was generated through Python code with the Faker library and structured based on patterns observed in public databases about customer behavior. The variables included churn rate, engagement, customer satisfaction rate (NPS – Net Promoter Score), contract and service type, payment method, and generated value. The applied methodology followed the BI cycle — data generation, preparation, analysis, and visualization — implemented through the Looker Studio tool. The results highlighted critical weaknesses, such as high churn rate, low customer engagement, negative NPS, and predominance of short-term contracts. From these analyses, an action plan was proposed to strengthen the Customer Success area, including continuous monitoring

of indicators, promotion of long-term contracts, and strategies to increase engagement. This study contributes to understanding the role of BI in the strategic management of customer retention in SaaS companies, reinforcing the importance of using data as a foundation for decision-making.

Keywords: *business intelligence; customer success; saas; churn metrics; customer retention.*

1 Introdução

O crescimento acelerado do mercado de *software*, impulsionado pela popularização dos modelos de assinatura e pela demanda por soluções escaláveis e acessíveis, tem consolidado o modelo *Software as a Service* (SaaS) como uma das principais estratégias de distribuição digital. Em um cenário altamente competitivo, a retenção de clientes e a criação de valor contínuo passaram a ser fatores críticos para a sustentabilidade das empresas. Nesse contexto, a adoção de práticas orientadas por dados e centradas no cliente tornou-se não apenas um diferencial, mas uma necessidade. Compreender o comportamento dos usuários, antecipar riscos de evasão (*churn*) e maximizar o engajamento são desafios que exigem ferramentas analíticas robustas e abordagens estratégicas como o *Customer Success* aliado ao *Business Intelligence* (BI).

Com o avanço dos modelos de negócio baseados em *Software as a Service* (Software como um Serviço), impulsionados pela transformação digital e pela adoção de soluções em nuvem (Mell; Grance, 2011), intensificou-se a necessidade de estratégias que promovam a retenção e o engajamento de clientes ao longo do tempo. Nesse contexto, a área de *Customer Success* (Sucesso do Cliente) tem se destacado como uma abordagem estratégica voltada a garantir que os clientes obtenham o valor esperado com os produtos ou serviços adquiridos, contribuindo diretamente para a redução da evasão (*churn*) e o aumento do valor gerado por cliente (Steinman; Murphy; Mehta, 2021; Dallabrida, 2023).

Aliada a essa abordagem, a utilização de ferramentas de *Business Intelligence* tem se tornado essencial para apoiar a tomada de decisão, por meio da coleta, organização e análise de grandes volumes de dados. O BI viabiliza a transformação de dados brutos em informações relevantes, promovendo ganhos operacionais e estratégicos, especialmente em ambientes organizacionais dinâmicos e competitivos (Santos; Gibertoni, 2022; Romero et al., 2021). Entre as soluções mais utilizadas nesse contexto, destacam-se os *dashboards* interativos, que oferecem visualizações dinâmicas e acessíveis, facilitando o acompanhamento de métricas e a identificação de padrões de comportamento dos clientes (Carvalho, 2019).

Este Trabalho de Conclusão de Curso, desenvolvido no curso de Sistemas de Informação, tem como objetivo analisar métricas de *Customer Success* em empresas que atuam no modelo *Software as a Service*, utilizando técnicas de *Business Intelligence* para apoiar a tomada de decisão. Para viabilizar esse objetivo, foi gerado um conjunto de dados sintéticos, gerado por meio de código em *Python* com a biblioteca *Faker*, com base em padrões observados em bases públicas, simulando o comportamento de clientes em empresas SaaS. A criação dessa base

própria permitiu maior controle sobre quais variáveis críticas seriam analisadas, como *churn* (taxa de evasão), engajamento, taxa de satisfação do cliente (NPS - *Net Promoter Score*), tipo de contrato e de serviço, método de pagamento, e valor gerado, assegurando a personalização necessária para o alcance dos resultados propostos. Os dados foram tratados e padronizados com foco na qualidade da análise e, posteriormente, integrados à ferramenta *Looker Studio*, utilizada para a construção do *dashboard* interativo e a visualização dos indicadores (Braghittoni, 2017 apud Santos; Gibertoni, 2022).

O artigo está organizado da seguinte forma: a seção 2 apresenta a revisão bibliográfica, abordando quatro eixos principais — *Business Intelligence*, modelos de serviço em nuvem, Customer Success e ferramentas de BI — que fundamentam a pesquisa. A seção 3 descreve os procedimentos metodológicos adotados, detalhando a geração, limpeza, preparação, análise e visualização dos dados. A seção 4 expõe o desenvolvimento do estudo, no qual o ciclo de BI é operacionalizado sobre o dataset sintético, incluindo a criação dos dados, o tratamento em R, a construção das métricas e a análise integrada do *dashboard*. A seção 5 apresenta o plano de ação elaborado a partir dos resultados, voltado ao fortalecimento da área de Customer Success. Por fim, a seção 6 reúne as conclusões, relacionando as conclusões aos objetivos iniciais e destacando as contribuições do estudo.

2 Revisão Bibliográfica

A revisão bibliográfica constitui etapa essencial para a fundamentação teórica de um trabalho científico, pois possibilita reunir, organizar e discutir o conhecimento já produzido acerca dos temas centrais relacionados ao objeto de estudo. Neste capítulo, são abordados quatro eixos principais que fornecem sustentação conceitual e metodológica à pesquisa. O primeiro deles é o *Business Intelligence*, considerado o núcleo do processo metodológico adotado neste trabalho, uma vez que está diretamente ligado às etapas de coleta, tratamento e análise de dados, bem como à geração de planos de ação estratégicos.

Em seguida, são discutidos os modelos de serviço em nuvem, cuja compreensão se faz necessária por este estudo simular a realidade de uma empresa de base tecnológica no formato *Software as a Service*, em que o serviço é disponibilizado por assinatura. O terceiro eixo diz respeito ao *Customer Success* (CS), que se mostra relevante por estar integrado às métricas analisadas e aos planos de ação derivados das análises de BI, representando um elo entre estratégia de retenção e valor entregue ao cliente.

Por fim, são exploradas as ferramentas de BI, com ênfase no *Looker Studio*, escolhido para este trabalho por sua facilidade de uso, ampla acessibilidade e custo zero, características que o tornam adequado para estudos acadêmicos e para empresas em estágios iniciais de maturidade analítica. Assim, a articulação desses quatro eixos fornece a base teórica necessária para compreender e aplicar a metodologia proposta, garantindo maior consistência às análises desenvolvidas nos capítulos subsequentes.

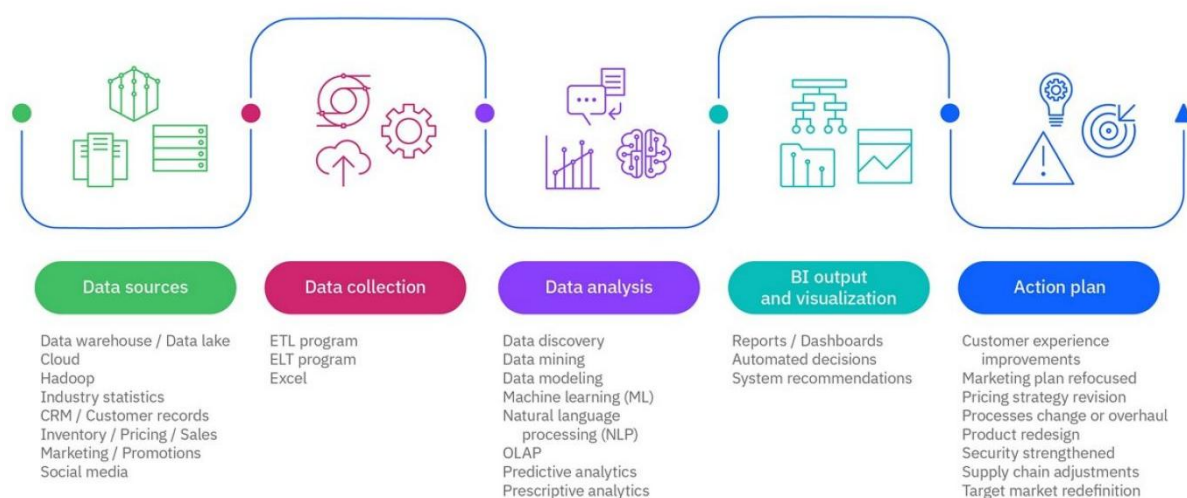
2.1 Business Intelligence (Inteligência de Negócio)

O conceito de *Business Intelligence* compreende a utilização de métodos e tecnologias para transformar dados em informações úteis à gestão, possibilitando decisões mais ágeis e fundamentadas, especialmente em ambientes organizacionais complexos e competitivos. Segundo Santos e Gibertoni (2022), o BI tem como objetivo fornecer suporte à tomada de decisão a partir da coleta, organização e análise de dados, promovendo melhorias operacionais e estratégicas dentro das empresas. Com a evolução tecnológica impulsionada pela Indústria 4.0, o BI passou a desempenhar um papel ainda mais crítico, permitindo análises avançadas e visualizações interativas que facilitam a tomada de decisões rápidas e informadas (Romero et al., 2021).

A Figura 1 ilustra de forma esquemática o ciclo de um processo de BI, destacando cinco etapas principais: fontes de dados, em que se reúnem registros de sistemas internos e externos; coleta de dados, com procedimentos de ETL (*Extract, Transform, Load*) ou ELT (*Extract, Load, Transform*); análise de dados, que envolve mineração, modelagem e técnicas de aprendizado de máquina; saídas e visualizações, representadas por relatórios e *dashboards* que sintetizam as informações obtidas; e, por fim, o plano de ação, no qual os resultados se convertem em melhorias práticas, como redefinição de estratégias de marketing, revisão de preços e aumento da experiência do cliente.

Dessa forma, observa-se que o ciclo de *Business Intelligence* não se limita a um processo técnico de manipulação de dados, mas representa uma abordagem estratégica que conecta informações internas e externas à realidade empresarial. Cada etapa — desde a integração das fontes até a definição de planos de ação — é essencial para transformar dados brutos em valor organizacional, apoiando gestores na identificação de oportunidades, mitigação de riscos e construção de vantagens competitivas sustentáveis.

Figura 1 - Diagrama de *Business Intelligence*



Fonte: IBM, 2025.

2.2 Modelos de Serviço em nuvem e a análise de dados

As análises realizadas através do processo de BI são de suma importância para diferentes segmentos de negócio sejam estes diretamente relacionados a tecnologia ou não. Este trabalho mostrará como dados podem ser analisados para apoiar as tomadas de decisão em uma empresa de tecnologia que oferece um serviço de software sobre inscrição ou *Software as a Service*, mais especificamente no departamento de Sucesso do cliente olhando para métricas relacionadas a retenção de clientes. Para tal, é importante definir os diferentes modelos de serviço em nuvem e suas características.

Segundo Mell e Grance (2011), os modelos de serviço em nuvem podem ser classificados em três categorias principais: *Infrastructure as a Service* (IaaS), *Platform as a Service* (PaaS) e *Software as a Service* (SaaS). Esses modelos se distinguem principalmente pelo nível de controle que o usuário possui sobre os recursos e pela responsabilidade da gestão.

2.2.1 *Infrastructure as a Service* (IaaS)

De acordo com Mell e Grance (2011), o modelo IaaS fornece ao consumidor “a capacidade de provisionar recursos computacionais fundamentais, como processamento, armazenamento e redes, onde o consumidor pode implantar e executar software arbitrário, incluindo sistemas operacionais e aplicações” (Mell; Grance, 2011, p. 2). Nesse cenário, o provedor é responsável apenas pela camada de infraestrutura, enquanto o cliente assume o gerenciamento de sistemas, dados e segurança.

Esse modelo é ideal para empresas que desejam maior controle sobre seu ambiente, sem precisar adquirir e manter servidores físicos. O IaaS é frequentemente utilizado por equipes técnicas que necessitam de ambientes configuráveis e altamente escaláveis.

2.2.2 *Platform as a Service* (PaaS)

O modelo PaaS oferece uma plataforma completa, permitindo aos clientes desenvolver, implantar e gerenciar aplicações sem a necessidade de lidar com a infraestrutura subjacente. Mell e Grance (2011) descrevem o PaaS como um modelo em que “o consumidor pode implantar na infraestrutura da nuvem aplicações criadas ou adquiridas usando linguagens de programação e ferramentas suportadas pelo provedor” (Mell; Grance, 2011, p. 2).

Neste modelo, o provedor é responsável por gerenciar servidores, armazenamento e rede, além de fornecer ferramentas de desenvolvimento, o que permite agilidade no ciclo de vida das aplicações e menor dependência de configurações complexas de infraestrutura.

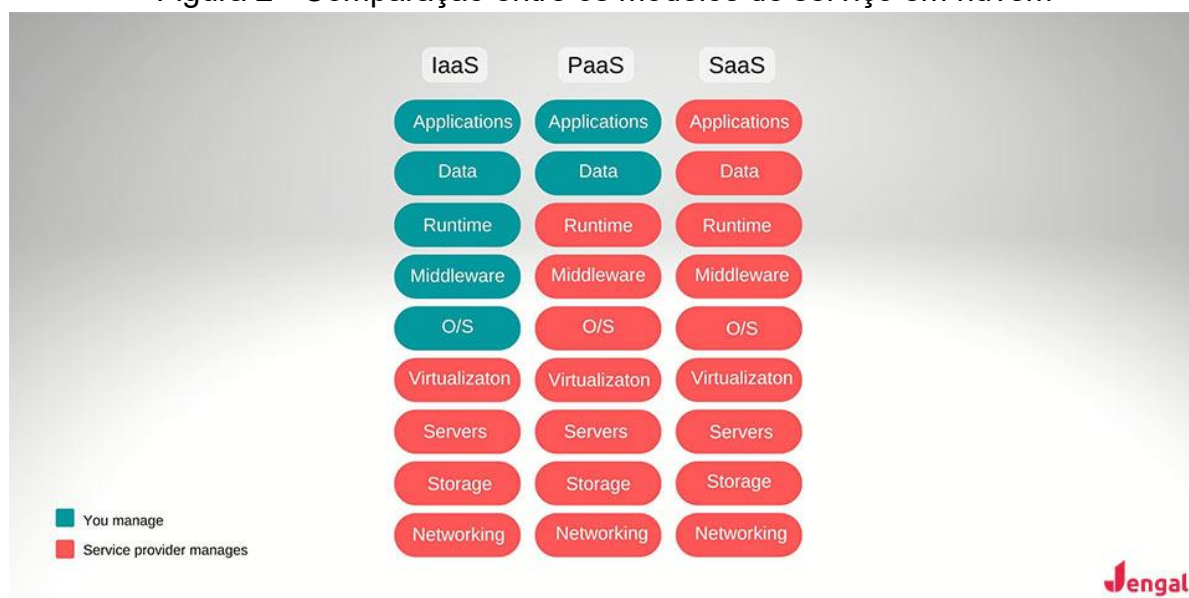
2.2.3 *Software as a Service* (SaaS)

O modelo *Software as a Service* (SaaS) refere-se à disponibilização de aplicações prontas para uso, executadas na infraestrutura do provedor e acessadas por meio de interfaces *web*. Nesse modelo, “o consumidor utiliza as aplicações do

provedor que são executadas na infraestrutura da nuvem e acessadas por meio de uma interface de cliente, como um navegador” (Mell; Grance, 2011, p. 2). O usuário não gerencia ou controla qualquer parte da infraestrutura, nem mesmo as configurações das próprias aplicações. O SaaS é amplamente adotado por organizações que buscam praticidade, baixo custo inicial e atualizações automáticas, sendo ideal para áreas como produtividade, *Customer Relationship Manager* (CRM) e colaboração corporativa.

A Figura 2 apresenta uma comparação visual entre os três modelos de serviço, destacando quais camadas ficam sob responsabilidade do cliente (em azul) e quais são gerenciadas pelo provedor (em vermelho). Observa-se que no IaaS o cliente administra desde os sistemas até os dados e aplicações, enquanto no PaaS a gestão do provedor se estende também ao *runtime* e *middleware*. Já no SaaS, todo o ambiente, incluindo aplicações e dados, é gerido pelo provedor, reforçando o caráter de praticidade e simplicidade desse modelo.

Figura 2 - Comparação entre os modelos de serviço em nuvem



Fonte: Jengal, 2025.

A análise comparativa entre os modelos de serviço em nuvem evidencia que a adoção de cada um deles está diretamente relacionada ao nível de autonomia e responsabilidade desejado pelas organizações. Enquanto IaaS e PaaS oferecem maior flexibilidade, mas também maior complexidade de gestão, o SaaS destaca-se pela simplicidade e pelo foco no uso imediato de aplicações. Essa diversidade de modelos reforça a importância de avaliar cuidadosamente o alinhamento entre necessidades de negócio, recursos disponíveis e estratégias de crescimento, garantindo que a infraestrutura tecnológica esteja em consonância com os objetivos organizacionais.

2.3. *Customer Success* (Sucesso do cliente)

A área de *Customer Success* vem se consolidando como uma abordagem proativa e estratégica que visa garantir que os clientes atinjam seus objetivos com o produto ou serviço contratado (Dallabrida, 2023). Esse conceito vai além do atendimento ou suporte, sendo responsável por alinhar valor percebido, engajamento e fidelização. Empresas que adotam uma cultura centrada no cliente e estruturam equipes de sucesso do cliente bem capacitadas conseguem aumentar significativamente sua taxa de retenção e o valor médio por cliente (Steinman; Murphy; Mehta, 2021; Dallabrida, 2023). Nesse cenário, o papel do *Customer Success Manager* (CSM) é essencial, atuando como ponto focal entre cliente e empresa, utilizando dados para personalizar a jornada e otimizar a entrega de valor.

Ferramentas de BI são fundamentais para o trabalho do CSM, pois permitem visualizar o histórico de interação do cliente, suas métricas principais e identificar oportunidades de *upsell* ou risco de cancelamento (Dallabrida, 2023).

A definição e utilização de métricas são cruciais para o monitoramento eficaz do *Customer Success* (CS). Steinman, Murphy e Mehta (2021) afirmam que algumas das métricas mais importantes nesse contexto incluem Renovações Brutas, Retenção Líquida, Adoção, Saúde do Cliente, Evasão (*Churn*), *Upsell* (sugerir uma opção que aumente o valor da venda), *Down Sell* (sugerir uma opção mais barata para evitar o cancelamento) e *Net Promoter Score* (NPS). A Tabela 1 apresenta os indicadores que serão analisados ao longo deste trabalho, cruciais para o monitoramento da área de *Customer Success*.

Alves (2021) destaca ainda outras métricas relevantes como a Receita Recorrente Mensal (MRR), *Lifetime Value* (LTV), Custo de Aquisição do Cliente (CAC), Ticket Médio e Taxa de *Churn*. Estas métricas são essenciais para entender o comportamento dos clientes, avaliar a saúde financeira e operacional da empresa e aprimorar as estratégias de retenção e expansão da base de clientes.

Embora o estudo de Alves (2021) apresente um conjunto abrangente de métricas voltadas à área de *Customer Success*, tais como *Lifetime Value*, Custo de Aquisição do Cliente e Receita Recorrente Mensal, sua aplicação não foi considerada neste trabalho. A decisão está associada à necessidade de manter maior controle sobre os indicadores selecionados e de trabalhar com dados sintéticos que simulam o comportamento de uma empresa SaaS em um cenário delimitado.

Dessa forma, a escolha concentrou-se em métricas específicas — churn, engajamento, NPS, tipo de contrato e de serviço, método de pagamento e valor gerado — que se mostraram suficientes para a análise pretendida, permitindo alinhar o processo de Business Intelligence à proposta metodológica do estudo.

Tabela 1 - Descrição dos indicadores.

Indicador	Descrição
Número de Clientes Ativos	Quantidade total de clientes que permaneceram ativos no período analisado.
Churn Rate (Taxa de Cancelamento)	Percentual de clientes que cancelaram seus serviços em um período determinado.
Receita Total, Receita Retida e Receita Perdida	Soma do valor gerado pelos clientes, distinguindo entre os que permaneceram ativos e os que cancelaram, permitindo mensurar o impacto financeiro da evasão.
Percentual de Valor Retido	Proporção da receita preservada em relação à receita total, evidenciando a capacidade da empresa em manter clientes e receitas recorrentes.
Receita Mensal Recorrente Média (RMRR)	Média da cobrança mensal dos clientes ativos, permitindo visualizar a estabilidade da receita.
Distribuição por Tipo de Contrato	Análise da proporção de clientes com contratos mensais, anuais ou bienais.
Engajamento por Uso	Categorização dos clientes conforme o nível de utilização dos serviços (alto, médio, baixo e inativo), permitindo identificar padrões de engajamento e risco de churn.

Fonte: Adaptado de Dallabrida, 2025.

2.4 Ferramentas de BI

No contexto das ferramentas de BI, destacam-se três soluções principais: *Power BI*, *Google Data Studio* (agora *Looker Studio*) e Planilhas Google. O *Power BI*, desenvolvido pela *Microsoft*, é altamente valorizado por sua capacidade de integração com diversos sistemas, interface intuitiva e facilidade para criação de *dashboards* interativos (Moraes, 2020; Damasceno; Alcalá, 2025).

O *Looker Studio* oferece uma abordagem colaborativa e baseada em nuvem, permitindo integração simplificada com outras ferramentas *Google*. Sua interface intuitiva, de arrastar e soltar, é ideal para equipes com pouca experiência técnica, destacando-se pelo baixo custo operacional e pela alta acessibilidade (CDLBM, 2019; Google Cloud, 2023).

Já as Planilhas *Google*, embora sejam ferramentas mais básicas, são frequentemente utilizadas como fonte de dados para *dashboards*, permitindo fácil manipulação e integração com outras soluções de BI, como o *Looker Studio*, facilitando análises rápidas e dinâmicas para equipes menores ou empresas em estágio inicial.

Existem diversas ferramentas de Business Intelligence (BI) no mercado, como *Tableau*, *Qlik Sense* e *SAS Visual Analytics*. Contudo, este trabalho foca em três soluções mais acessíveis e aplicáveis a empresas que buscam analisar métricas de customer success: *Power BI*, *Google Data Studio (Looker Studio)* e Planilhas Google. O *Power BI* é valorizado pela integração com múltiplas fontes de dados e recursos avançados de *dashboards* (Moraes, 2020; Damasceno; Alcalá, 2025). O *Looker Studio*, gratuito e colaborativo, destaca-se pela integração ao ecossistema Google e facilidade de uso. Já as Planilhas Google, embora mais simples, são amplamente utilizadas pela praticidade e colaboração em tempo real. Assim, embora não esgotem o leque de opções disponíveis, essas ferramentas foram escolhidas pela pertinência e aplicabilidade ao contexto estudado. A Tabela 2 faz uma comparação entre as plataformas *Power BI* e *Looker Studio*.

Tabela 2 - Comparação entre as plataformas *Power BI* e *Looker Studio*.

Critério	<i>Power BI</i>	<i>Looker Studio</i>
Interface	Intuitiva, porém com curva de aprendizado	Altamente intuitiva, fácil aprendizado
Integrações	Amplas integrações com serviços <i>Microsoft</i>	Excelentes integrações com serviços <i>Google</i>
Colaboração	Boa, porém depende da assinatura premium	Excelente e gratuita
Custo	Gratuito com limitações; versões pagas avançadas	Totalmente gratuito
Complexidade das análises	Alta capacidade de análises avançadas	Análises básicas e intermediárias
Acessibilidade	Aplicativo <i>desktop</i> e <i>web</i>	Exclusivamente <i>web</i> , acessível de qualquer lugar

Fonte: Adaptado de Damasceno; Alcalá, 2025.

3 Procedimentos Metodológicos

Este capítulo apresenta os procedimentos metodológicos adotados para construção de um processo de *Business Intelligence* voltado à análise de métricas de *Customer Success* em empresas que operam no modelo *Software as a Service*. A metodologia segue as principais etapas do ciclo de BI — geração, preparação, análise e visualização de dados — e está fundamentada na literatura sobre BI e gestão da experiência do cliente.

3.1 Geração dos dados

O desenvolvimento de *dashboards* analíticos voltados à análise de métricas de *Customer Success* em empresas SaaS requer uma base de dados consistente, capaz de simular cenários de comportamento de clientes, seus contratos e padrões de utilização. Para este estudo, foram inicialmente considerados dois conjuntos de dados públicos disponibilizados na plataforma *Kaggle*, ambos voltados à análise de *churn*.

O primeiro conjunto de dados, elaborado por Willian Oliveira Gibin, contempla variáveis contratuais e financeiras de clientes de uma empresa de serviços contínuos. Entre os atributos presentes, destacam-se: tempo de permanência (*tenure*), tipo de contrato, método de pagamento, valor mensal, valor total pago e indicador de cancelamento (*churn*). Esses dados permitem a extração de métricas como *churn rate*, *lifetime value* (LTV) e *monthly recurring revenue* (MRR).

O segundo conjunto de dados, elaborado por Muhammad Shahid Azeem, complementa o primeiro ao incluir variáveis demográficas e comportamentais, como idade, gênero, duração da assinatura, data da última interação, pacotes de serviços contratados e nível de utilização. Tais informações viabilizam análises de engajamento e segmentação por perfil, ampliando a compreensão sobre os fatores associados ao cancelamento de clientes. Como destacam Steinman, Murphy e Mehta (2021, p. 89), “a compreensão profunda dos perfis e padrões de comportamento dos clientes é essencial para prever riscos de *churn* e aplicar estratégias proativas de retenção”.

Apesar da relevância dos conjuntos de dados mencionados, optou-se por não utilizá-los diretamente em função de suas limitações quanto ao alinhamento com os objetivos deste estudo. Em seu lugar, foi gerado um conjunto de dados sintéticos, composto por 10.153 registros, estruturados a partir das variáveis e padrões observados em bases públicas. A escolha justifica-se pela necessidade de simular o comportamento de uma empresa SaaS em um cenário controlado, ainda que baseado em dados gerados de forma aleatória.

As variáveis incluídas no dataset são: identificador do cliente (*CustomerID*), idade (*Age*), gênero (*Gender*), tempo de permanência (*Tenure*), tipo de contrato (*ContractType*), método de pagamento (*PaymentMethod*), valor da mensalidade (*MonthlyCharges*), valor total pago (*TotalCharges*), indicador de cancelamento (*Churn*), duração da assinatura (*SubscriptionLength*), último contato com a empresa (*LastInteraction*), pacote de serviços contratados (*ServicesEnrolled*) e nível de utilização (*Usage*).

3.2. Limpeza e preparação dos dados

A qualidade dos dados constitui um aspecto crítico para o sucesso das estratégias baseadas em dados, assegurando que as decisões sejam fundamentadas em informações confiáveis e relevantes. Dados incorretos, incompletos, desatualizados ou inconsistentes podem comprometer as análises e levar a decisões inadequadas, com impactos negativos significativos nas operações empresariais (Braghittoni, 2017 apud Santos; Gibertoni, 2022).

Com a base de dados inicial gerada, foi necessário realizar um processo de limpeza e preparação dos dados, a fim de garantir que os registros estivessem consistentes e prontos para análise. Essa etapa é essencial em projetos de *Business Intelligence*, pois a qualidade dos dados impacta diretamente na confiabilidade dos resultados obtidos a partir das visualizações e indicadores. O processo de limpeza e preparação foi realizado diretamente no R, após a importação da base de dados as colunas em inglês foram renomeadas para português, além de tratar inconsistências de formato e a padronização das variáveis categóricas, realizando a divisão da coluna *Serviços_Inscritos* em colunas binárias ao invés de texto para facilitar o cálculo de contratação por serviço.

Outro aspecto relevante refere-se à quantidade de registros removidos. A base inicial continha 10.153 registros, dos quais restaram 4.366 registros após a limpeza. Embora a exclusão de dados seja necessária em casos de inconsistências graves ou valores ausentes impossíveis de recuperar, é importante avaliar a proporção de itens descartados, pois a remoção excessiva pode reduzir a representatividade da amostra e enviesar os resultados. Em outros contextos, registros incompletos poderiam ser tratados de formas alternativas, como a imputação de valores médios, a aplicação de técnicas estatísticas para preenchimento de lacunas, a segmentação de análises considerando grupos de qualidade distinta ou com a ajuda de um especialista.

3.3. Análise dos Dados

Foram selecionadas métricas amplamente conhecidas no contexto de *Customer Success*, conforme destacado por Alves (2021) e Steinman, Murphy e Mehta (2021), permitindo o monitoramento do comportamento dos clientes e da saúde financeira da empresa. As métricas calculadas incluem:

- Número de Clientes Ativos: corresponde ao total de clientes que permaneceram ativos no período analisado.
- *Churn Rate* (Taxa de Cancelamento): representa a porcentagem de clientes que cancelaram seus serviços, calculada pela relação entre clientes perdidos e o total de clientes no início do período conforme a Equação 1.

$$Churn Rate = \left(\frac{Clientes\ Perdidos}{Total\ de\ Clientes\ no\ Início\ do\ Período} \right) \times 100 \quad (1)$$

- Receita Total, Receita Retida e Receita Perdida: cálculo da soma do valor gerado pelos clientes, distinguindo-se entre os que permaneceram ativos e os que cancelaram. Essa métrica permite mensurar o impacto financeiro da evasão.
- Percentual de Valor Retido: proporção da receita preservada em relação à receita total, evidenciando a capacidade da empresa em manter clientes e receitas recorrentes.
- Receita Mensal Recorrente Média (RMRR): obtida pela média da cobrança mensal dos clientes ativos, permitindo visualizar a estabilidade da receita.
- Distribuição por Tipo de Contrato: análise da proporção de clientes com contratos mensais, anuais ou bienais.

- Engajamento por Uso: categorização dos clientes conforme o nível de utilização dos serviços (alto, médio, baixo e inativo), permitindo identificar padrões de engajamento e risco de *churn*.
- Distribuição por Serviço e Método de Pagamento: análise da quantidade de clientes por serviço contratado (CRM, *Analytics*, *Billing*, *Live Chat* e *Email Marketing*) e dos principais métodos de pagamento (cartão de crédito, débito automático, boleto e Pix).
- *Net Promoter Score* (NPS): indicador de satisfação e lealdade dos clientes, obtido por meio da pergunta “Em uma escala de 0 a 10, qual a probabilidade de você recomendar a empresa a um amigo ou colega?”. Os clientes são classificados em promotores (9 e 10), neutros (7 e 8) e detratores (0 a 6). O NPS é calculado pela diferença entre o percentual de promotores e o percentual de detratores, conforme a Equação 2.

$$NPS = \%Promotores - \%Detratores \quad (2)$$

O uso de indicadores-chave de desempenho (KPIs) é essencial para apoiar a tomada de decisão e alinhar estratégias de retenção, expansão e engajamento dos clientes (Santos; Gibertoni, 2022).

3.4 Visualização

A análise e visualização de dados são fundamentais para transformar grandes quantidades de informações complexas em *insights* acessíveis e compreensíveis, permitindo a tomada de decisões mais informadas. Visualizações bem estruturadas são capazes de sintetizar e comunicar rapidamente informações essenciais, ajudando gestores e equipes a detectar padrões, correlações e anomalias com eficiência.

De acordo com Carvalho (2019), visualizações bem estruturadas, como gráficos de barras, gráficos de linhas, mapas de calor, gráficos circulares e *dashboards* interativos, permitem detectar padrões, correlações e anomalias com eficiência. A escolha da técnica de visualização deve considerar tanto a natureza das informações quanto o objetivo da análise, assegurando clareza e relevância na comunicação dos resultados. Assim, essa etapa conecta-se diretamente ao uso prático dos indicadores, permitindo que gestores interpretem os dados de forma ágil e fundamentada.

O processo de construção das métricas neste trabalho ocorreu por meio da integração da base de dados no *Google Looker Studio*, a fim de possibilitar a análise exploratória e a visualização dos principais indicadores de *Customer Success*. De acordo com Santos e Gibertoni (2022), a utilização de ferramentas de *Business Intelligence* permite transformar dados dispersos em informações estratégicas, apoiando a tomada de decisão e a identificação de tendências. Para cada métrica selecionada, foram seguidos os mesmos passos metodológicos:

- Definição da métrica com base na literatura de *Customer Success*;
- Construção do campo calculado no Looker Studio;

- Configuração do gráfico de representação mais adequado (scorecard, pizza, barra ou linha temporal);
- Interpretação dos resultados e análise comparativa.

4 Desenvolvimento

Esta seção descreve a etapa de desenvolvimento do estudo, na qual o ciclo de *Business Intelligence* é operacionalizado sobre o conjunto de dados proposto. Seguindo as fases adotadas no trabalho — geração, preparação, análise e visualização — detalham-se, respectivamente: (4.1) a criação dos dados sintéticos em Python (Geração de Dados), (4.2) os procedimentos de limpeza e padronização realizados em R (Limpeza e Preparação), (4.3) a construção das métricas e dos cálculos necessários (Análise e Visualização) e (4.4) a leitura integrada dos resultados no painel final (Análise do *Dashboard*). Essa organização reflete o encadeamento metodológico já apresentado no documento (geração, preparação, análise e visualização), garantindo coerência entre fundamentação e execução prática do BI no contexto SaaS proposto.

4.1 Geração de Dados

A etapa inicial do processo de *Business Intelligence* neste trabalho consistiu na criação do conjunto de dados, etapa equivalente à coleta de dados do ciclo de BI. Para tal, foi desenvolvido um código em linguagem Python utilizando a biblioteca *Faker*, de modo a gerar registros fictícios que simulassem características de clientes em empresas SaaS como mostra a Figura 3. O código completo está disponível em repositório público no GitHub (<https://github.com/4ugu5t0/TCC>), garantindo transparência e reprodutibilidade do estudo.

Figura 3 – Código Python para a geração dos dados sintéticos

```
1 import pandas as pd # type: ignore
2 import numpy as np # type: ignore
3 import random
4 from faker import Faker # type: ignore
5 # Inicialização
6 fake = Faker()
7 num_records = 10153
8 # Funções auxiliares
9 def random_services():
10     services = ['Analytics', 'CRM', 'Email-Marketing', 'Hosting', 'SEO-Tools']
11     return ' '.join(random.sample(services, k=random.randint(1, len(services))))
12 def random_usage():
13     return round(np.random.normal(loc=50, scale=20), 2)
14 # Geração dos dados
15 data = {
16     "CustomerID": [fake.uuid4() for _ in range(num_records)],
17     "Age": np.random.choice([np.nan] + list(range(18, 70)), num_records),
18     "Gender": np.random.choice([np.nan, 'Male', 'Female', 'Other'], num_records, p=[0.05, 0.45, 0.45, 0.05]),
19     "Tenure": np.random.choice([np.nan] + list(range(1, 61)), num_records),
20     "ContractType": np.random.choice([np.nan, 'Mensal', 'Anual', 'Bienal'], num_records, p=[0.05, 0.5, 0.3, 0.15]),
21     "PaymentMethod": np.random.choice([np.nan, 'Cartão de Crédito', 'Boleto', 'Transferência', 'Paypal'], num_records),
22     "MonthlyCharges": np.round(np.random.uniform(20, 300, num_records), 2),
23     "TotalCharges": [round(mc * random.randint(1, 60), 2) for mc in np.random.uniform(20, 300, num_records)],
24     "Churn": np.random.choice(['Yes', 'No'], num_records, p=[0.3, 0.7]),
25     "SubscriptionLength": np.random.choice([np.nan] + list(range(1, 61)), num_records),
26     "LastInteraction": [fake.date_between(start_date='-2y', end_date='today') for _ in range(num_records)],
27     "ServicesEnrolled": [random_services() for _ in range(num_records)],
28     "Usage": [random_usage() if random.random() > 0.05 else np.nan for _ in range(num_records)]
29 }
30 df = pd.DataFrame(data)
31 # Exportação para Excel
32 excel_path = "/mnt/data/dados_mockados_saas.xlsx"
33 df.to_excel(excel_path, index=False)
34 import ace_tools as tools; tools.display_dataframe_to_user(name="Dados Mockados SaaS", dataframe=df) # type: ignore
35 excel_path
```

Fonte: Autor.

Para ilustrar o modo como os dados sintéticos foram gerados, considerou-se a linha 20 do código que define a variável “ContractType” como exemplo, que aparece no dicionário data usado para compor o *DataFrame*. Nessa linha vista na Figura 4, utiliza-se a função “*np.random.choice*” da biblioteca *NumPy* para sortear valores entre quatro possibilidades, sendo elas *np.nan* (valor ausente), “Mensal”, “Anual” e “Bienal”, para cada um dos registros — o número total de registros está definido anteriormente na variável *num_records* (neste caso, 10153). O parâmetro *p=[0.05, 0.5, 0.3, 0.15]* atribui probabilidades a cada uma das categorias: 5 % dos registros ficam com valor ausente, 50 % com contrato mensal, 30 % com contrato anual e 15 % com contrato bienal.

Figura 4 – Linha de código para definição de tipo de contrato (“ContractType”)

```
20 ..... "ContractType": np.random.choice([np.nan, 'Mensal', 'Anual', 'Bienal'], num_records, p=[0.05, 0.5, 0.3, 0.15]),
```

Fonte: Autor.

O código foi estruturado para gerar valores aleatórios a partir de intervalos pré-definidos, contemplando variáveis como idade, gênero, tempo de permanência, tipo de contrato, forma de pagamento, mensalidade, valor total pago, utilização do serviço e indicador de *churn*. Ao término da execução, os registros foram exportados no formato CSV, por meio da função “*excel_path*”, permitindo sua posterior importação em ferramentas de análise como R, Google Planilhas e *Looker Studio*.

4.2 Limpeza e Preparação dos dados

A etapa de limpeza foi conduzida em R via R Markdown, importando “dados_mockados_saas.xlsx” e renomeando variáveis conforme convenções estáveis (sem espaços, acentos, abreviações consistentes). Essa padronização reduz erros em junções e cálculos, simplifica a documentação e os testes e garante reprodutibilidade, de modo que o processo mostrado na Figura 5 possa ser replicado com mínima intervenção.

Para renomear as variáveis, utilizou-se a função “*rename()*” do pacote *dplyr*. Nessa operação, a função *rename()* é aplicada ao objeto dados, que contém o conjunto de dados importado. O operador “*%>%*” (*pipe*) é utilizado para encadear as operações de forma sequencial. Para cada variável no conjunto de dados, o nome atual é mapeado para o novo nome desejado. Por exemplo, a variável “*Gender*” é renomeada para “*Sexo*”, “*Churn*” para “*Evasão*”, e assim por diante. Essa prática de renomeação visa tornar os nomes das variáveis mais descritivas e alinhados com a terminologia utilizada na análise, facilitando a compreensão e interpretação dos dados.

Figura 5 – Código em R renomeando a base

```
23 #Renomeando a base
24 ```{r}
25 dados <- dados %>%
26   rename(
27     ID_Consumidor = CustomerID,
28     Idade = Age,
29     Sexo = Gender,
30     Fidelidade_em_Meses = Tenure,
31     Tipo_de_Contrato = ContractType,
32     Método_de_pagamento = PaymentMethod,
33     Cobrança_Mensal = MonthlyCharges,
34     Valor_Total = TotalCharges,
35     Evasão = Churn,
36     Duração_da_Assinatura = SubscriptionLength,
37     Última_interação_CSM = LastInteraction,
38     NPS = NPS,
39     Login_ultima_semana = LoginsLastWeek,
40     Uso = Usage,
41     Serviços_Inscritos = ServicesEnrolled
42   )
43 dados
44 ```
```

Fonte: Autor.

Após o processo de renomeação é necessário padronizar as variáveis categóricas, realizando a divisão da coluna “Serviços_Inscritos” em colunas binárias ao invés de texto para facilitar o cálculo como na Figura 6 para a análise de serviços contratados. Esse trecho de código cria uma lista fixa de serviços (por exemplo, “*Email Marketing*”, “*CRM*”, “*Analytics*”, “*Billing*”, “*Live Chat*”) e percorre cada elemento dessa lista (cada serviço) para gerar uma nova coluna no dataset; cada nova coluna funciona como variável binária que indica se o serviço correspondente está presente ou não no registro do cliente. O laço “*for (serviço in services)*” define o ciclo de repetição para cada serviço na lista. Dentro dele, define-se “*nome_coluna <- gsub(" ", "_", serviço)*” para transformar o nome do serviço em nome de coluna amigável (substituindo espaços por “_”).

Em seguida, o código da linha 53 da Figura 6 avalia, para cada registro, se o serviço em questão está presente na string da coluna “*Serviços_Inscritos*”; a função “*strsplit(...)*” divide a string em substrings separadas por vírgula, “*unlist(...)*” irá desmembrar a lista resultante, “*trimws(...)*” remove espaços em branco nas extremidades de cada substring, e “*%in%*” retorna *TRUE* (Verdadeiro) ou *FALSE* (Falso) indicando presença ou ausência. Esse procedimento transforma uma coluna de texto com múltiplos serviços inscritos num conjunto de colunas binárias, facilitando análises estatísticas como cálculos de frequência, agrupamentos ou regressões, que em geral lidam melhor com variáveis numéricas ou lógicas do que com listas ou *strings* (cadeias de caracteres).

Figura 6 – Código em R para separação das colunas

```
45 #Separando a String serviço em colunas separadas
46 ```{r}
47 # Lista dos serviços
48 servicos <- c("Email Marketing", "CRM", "Analytics", "Billing", "Live Chat")
49
50 # Laço para criar uma coluna para cada serviço
51 for (servico in servicos) {
52   nome_coluna <- gsub(" ", "_", servico) # transforma para nome de coluna amigável
53   dados[[nome_coluna]] <- sapply(dados$Servicos_Inscritos, function(x) {
54     servico %in% trimws(unlist(strsplit(x, ","))) # separa, tira espaços, verifica se está
55     presente
56   })
57 }
```

Fonte: Autor.

Após essa conversão os resultados gerados são *TRUE* e *FALSE* que então foram convertidos para valores inteiros “1” e “0”, conforme mostra a Figura 7. Esse procedimento foi realizado definindo-se um vetor com os nomes das colunas que contêm valores lógicos (por exemplo, “Email_Marketing”, “CRM”, “Analytics”, “Billing”, “Live_Chat”) e aplicando-se a função “*lapply*” sobre esse subconjunto “*cols_para_converter <- c(...)*”, de modo a transformar cada coluna lógica em lógica explícita (*TRUE* ou *FALSE*) e então convertê-la em inteiro. A função “*as.integer()*” é usada para essa conversão, pois em R o valor lógico *TRUE* é interpretado como 1 e *FALSE* como 0 quando convertido para inteiro.

Figura 7 – Código em R convertendo os valores

```
77 #Converter TRUE FALSE em valores inteiros
78 ```{r}
79 cols_para_converter <- c("Email_Marketing", "CRM", "Analytics", "Billing", "Live_Chat")
80 dados_sem_ausentes[cols_para_converter] <- lapply(dados_sem_ausentes[cols_para_converter],
81   function(x) as.integer(x))
82
```

Fonte: Autor.

Para viabilizar a análise quantitativa, aplicou-se lógica booleana, atribuindo o valor “1” para indicar a contratação do serviço e “0” para a ausência de contratação. Essa transformação, ilustrada na Figura 8, permitiu maior precisão no tratamento dos dados e possibilitou a construção de métricas segmentadas por tipo de serviço.

Figura 8 – Colunas separadas por serviço

Serviços_Inscritos	NPS	Login_ultima_se Uso	Email_Marketing CRM	Analytics	Billing	Live_Chat
Analytics, Email Marketing, CRM,	8	3 Médio	1	1	1	0
Analytics, CRM	9	5 Alto	0	1	1	0
CRM, Live Chat, Email Marketing	0	2 Baixo	1	1	0	1
Billing, Live Chat, CRM	3	3 Médio	0	1	0	1
CRM, Email Marketing	6	0 Inativo	1	1	0	0
Live Chat, Billing, CRM, Email Ma	3	1 Baixo	1	1	1	1
Live Chat, Analytics, Email Marke	9	2 Baixo	1	1	1	1
Billing, Live Chat, Email Marketing	8	2 Baixo	1	0	0	1
Analytics	5	2 Baixo	0	0	1	0

Fonte: Autor.

Por fim, os dados brutos simulados, os quais apresentavam registros com campos incompletos e inconsistências, foram normalizados. A Figura 9 ilustra um recorte desse conjunto de dados, evidenciando valores ausentes em variáveis críticas para a análise.

Figura 9 – Planilha com os dados nulos

CustomerID	Age	Gender	Tenure	ContractType	PaymentMethod	MonthlyCharges	TotalCharges
CUST00001	50	Female	29	Mensal	Pix	348,65	10110,85
CUST00002	57		31	Mensal	Débito Automático	314,67	9754,77
CUST00003	22	Female	19	Bienal	Débito Automático	249,06	4732,14
CUST00004	50	Male		Mensal	Débito Automático	388,2	
CUST00005		Female	4	Mensal	Débito Automático	307,65	1230,6
CUST00006	25	Male	55	Mensal	Cartão de Crédito	377,34	20753,7
CUST00007	41	Male	43	Mensal	Pix	271,1	11657,3
CUST00008	68	Female	37	Mensal		481,7	17822,9

Fonte: Autor.

Para a remoção dos dados, utilizou-se a linguagem R, empregando a função “*na.omit()*” na linha 68 da Figura 10, responsável por remover todas as linhas (tuplas) que apresentavam valores nulos (NA) em qualquer uma das colunas. Esse procedimento, exemplificado abaixo, assegurou que apenas registros completos fossem mantidos na base final, preservando a consistência e a confiabilidade das análises. A exclusão de dados ausentes segue a recomendação de Santos e Gibertoni (2022), que destacam a importância da qualidade dos dados como pré-requisito para que os indicadores de *Business Intelligence* forneçam informações válidas para a tomada de decisão.

Figura 10 – Código em R para remoção de dados ausentes.

```

66 #exclui os dados ausentes
67 ```{r}
68 dados_sem_ausentes <- na.omit(dados)
69 nrow(dados_sem_ausentes)
70 ```

```

Fonte: Autor.

O resultado desse processo foi exportado para o arquivo “*dados_sem_ausentes.csv*”, que passou a ser utilizado como fonte principal de dados para a construção do *dashboard* na ferramenta Looker Studio. A escolha pelo formato .csv se justifica por sua leveza e ampla compatibilidade com plataformas de visualização de dados. A Figura 11 apresenta um recorte da versão já tratada do conjunto de dados, na qual se observa a ausência de tuplas incompletas, em contraste com a Figura 10, o que assegura maior consistência às análises realizadas.

Figura 11 – Planilha com tuplas vazias removidas

ID_Consumidor	Idade	Sexo	Fidelidade_em_	Tipo_de_Contra	Método_de_pag	Cobrança_Mens	Valor_Total
CUST00006	25	Male	55	Mensal	Cartão de Crédito	377,34	20.753,70
CUST00007	41	Male	43	Mensal	Pix	271,10	11.657,30
CUST00010	19	Female	28	Mensal	Débito Automático	251,12	7.031,36
CUST00012	30	Other	55	Anual	Boleto	483,65	26.600,75
CUST00014	57	Female	29	Mensal	Cartão de Crédito	156,12	4.527,48
CUST00015	57	Female	10	Mensal	Boleto	192,24	1.922,40
CUST00016	34	Male	51	Mensal	Débito Automático	402,52	20.528,52
CUST00017	34	Female	4	Anual	Boleto	267,62	1.070,48
CUST00022	67	Male	27	Bienal	Débito Automático	272,62	7.360,74

Fonte: Autor.

A aplicação dessas etapas garantiu a eliminação de registros vazios e inconsistências formais, resultando em um conjunto de dados mais adequado para análise. Contudo, por se tratar de informações geradas de forma aleatória, não é possível assegurar consistência total entre as variáveis. Assim, as análises conduzidas refletem simulações próximas ao comportamento esperado em empresas SaaS, sem, entretanto, representar um retrato fiel de uma base real de clientes.

4.3 Análise e Visualização

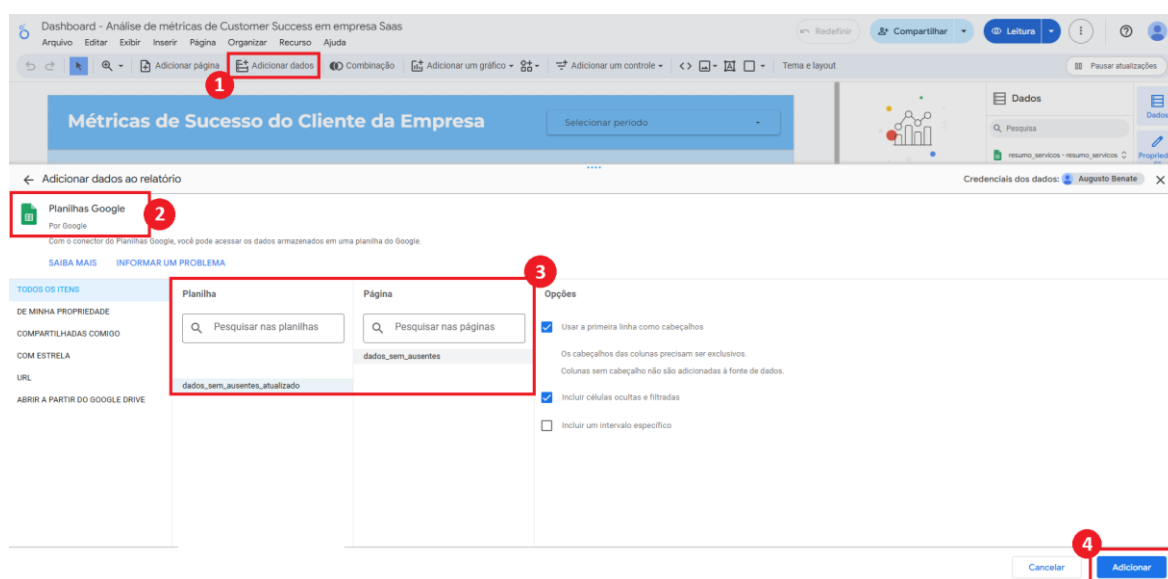
A presente seção de Análise e Visualização dedica-se a mostrar como se construiu, a partir dos dados preparados e limpos, o gráfico “Nível de Atividade dos Clientes Ativos”. Esse gráfico utiliza a coluna “Uso” como dimensão e “Record Count” como métrica, de modo a mostrar quantos clientes se encontram nos níveis de atividade Alto, Médio, Baixo ou Inativo. O propósito dessa métrica é revelar rapidamente a distribuição de uso dentro da base ativa, identificando segmentos com menor engajamento que podem demandar intervenções de retenção. A visualização escolhida para essa análise foi o gráfico de pizza, por sua clareza em exibir proporções para poucas categorias definidas. Conforme Alves (2021) e Santos; Gibertoni (2022), métricas de engajamento e distribuição de uso são fundamentais para monitorar a saúde de clientes e orientar ações de Customer Success.

Cabe destacar que, para assegurar reprodutibilidade, o procedimento a seguir descreve integralmente as operações realizadas no *Looker Studio* utilizando a própria base limpa (Dimensão = Uso; Métrica = *Record Count*) e o gráfico de pizza, conforme a interface vigente na data desta versão. Como nomes de menus, opções e comportamentos podem sofrer ajustes em atualizações do produto, recomenda-se que o leitor consulte, durante a execução, a documentação oficial: como adicionar gráficos ao relatório, as regras do gráfico de pizza (uma dimensão e uma métrica), a definição de contagem de registros/COUNT e, quando necessário, a configuração de filtros no componente (Google, 2025a; Google, 2025b; Google, 2025c; Google, 2025d).

4.3.1 Procedimento (passo a passo) para gerar o gráfico Nível de atividade dos Clientes Ativos

1. Conectar a base limpa ao relatório. No *Looker Studio*, pode-se abrir (ou criar) o relatório e adicionar a fonte de dados que contém a tabela tratada. Para isso, conforme ilustrado na Figura 12, o processo é realizado em quatro etapas principais: (1) selecionar a opção *Adicionar dados* no editor; (2) escolher a fonte de dados “Planilhas Google”; (3) localizar a planilha e a aba correspondente ao conjunto de dados tratados; e (4) clicar em *Adicionar* para concluir a conexão. A partir desse momento, todos os campos ficam disponíveis no painel de propriedades do relatório, podendo ser utilizados na construção dos gráficos e indicadores.

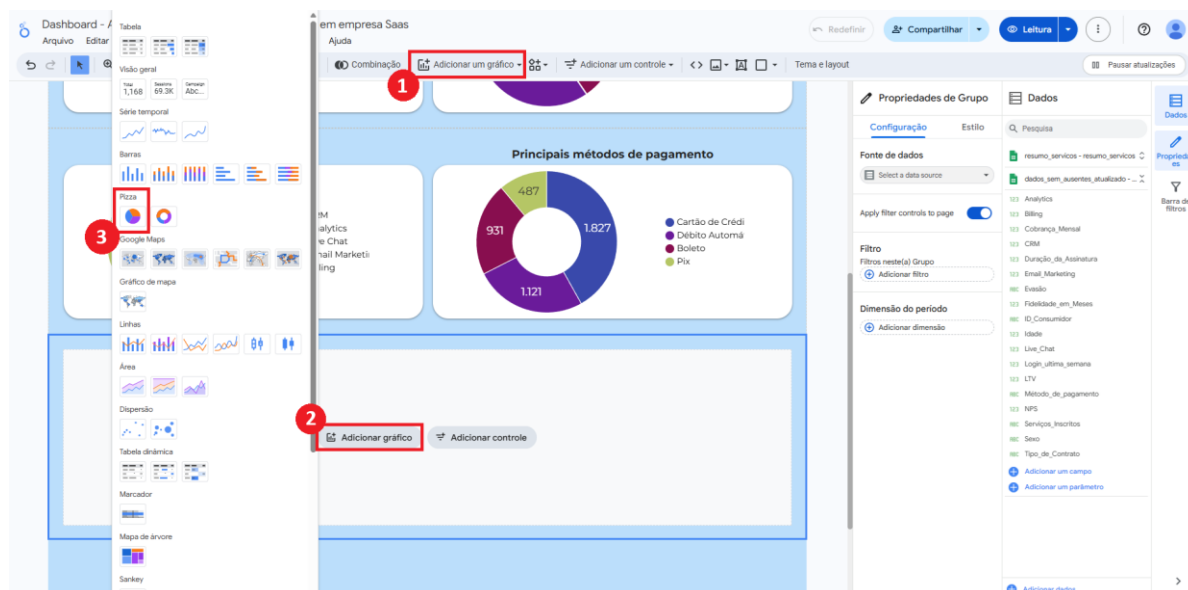
Figura 12 – Conexão da planilha de dados no Looker Studio



Fonte: *Looker Studio*, 2025, on-line.

2. Inserir o componente de visualização. Com o relatório em modo de edição, pode-se acionar a opção *Adicionar gráfico* (1), ou diretamente em uma seção editável do *Dashboard* (2) selecionar o tipo *Pizza* (3). Conforme ilustrado na Figura 13, a criação de gráficos segue um fluxo simples: entrar no modo de edição, adicionar o gráfico desejado e, por fim, posicioná-lo e dimensioná-lo no *canvas* do *dashboard*.

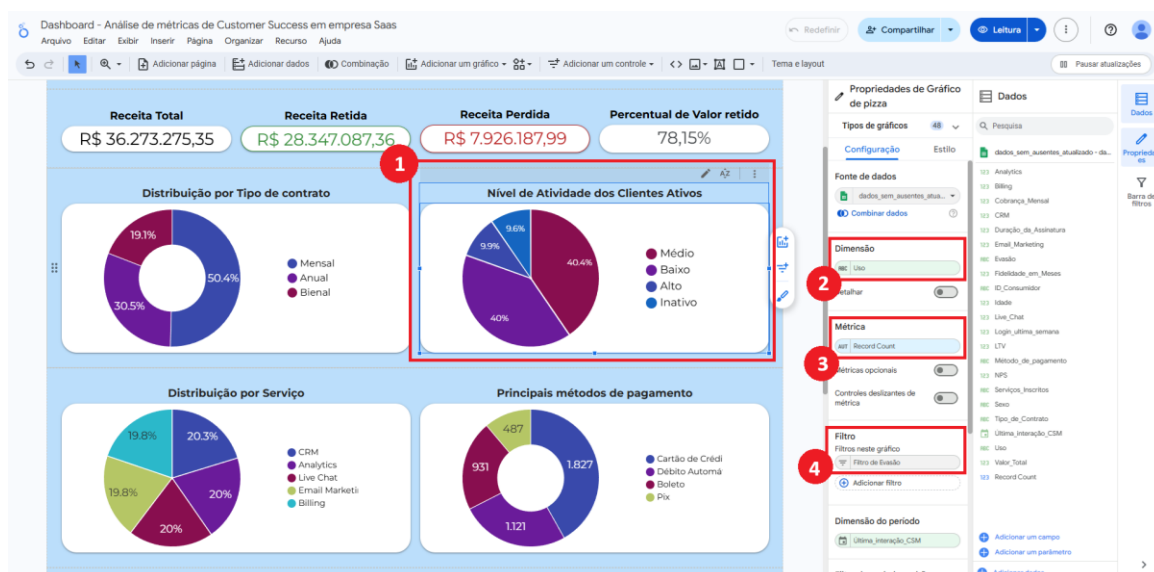
Figura 13 – Inserção de gráfico de pizza no Looker Studio



Fonte: Looker Studio, 2025, on-line.

3. Configurar os campos do gráfico. Ao selecionar o gráfico (1) como ilustrado na Figura 14, vemos no menu lateral a direita no painel Setup/Dados do gráfico, que é possível selecionar a opção de Dimensão: Uso (2), que contém as categorias Alto, Médio, Baixo e Inativo, e a opção de Métrica: *Record Count* (3), responsável por contabilizar a quantidade de registros em cada categoria. No Looker Studio, métricas são agregações aplicadas aos dados (por exemplo, somas, médias ou contagens), e o Record Count reflete a contagem de linhas/registros usada para quantificar ocorrências por categoria.

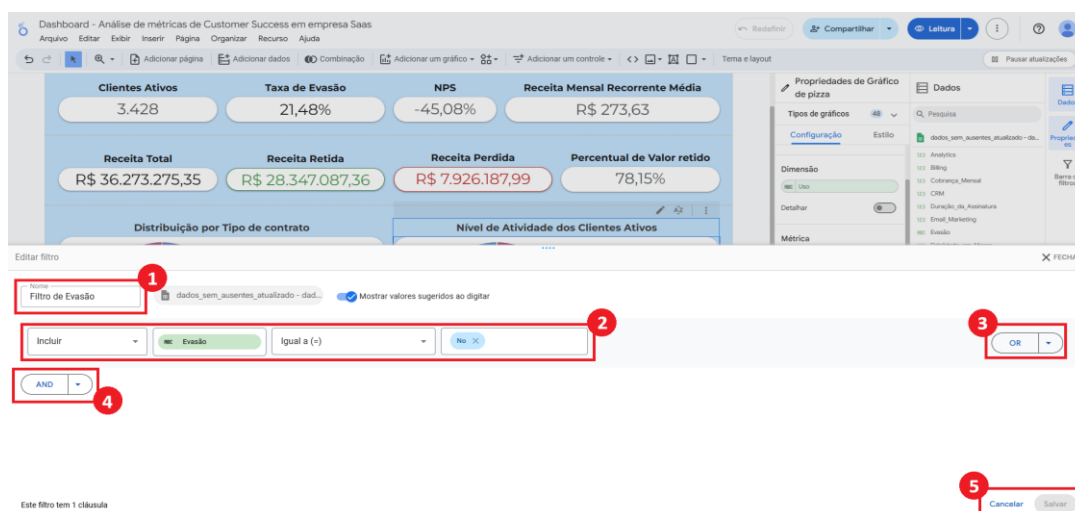
Figura 14 – Configuração do gráfico de nível de atividade dos clientes no *Looker Studio*



Fonte: *Looker Studio*, 2025, on-line.

4. Aplicar (se necessário) filtro para clientes ativos. Caso a base possua o campo de status, pode-se adicionar um filtro ao gráfico (4), ilustrado na Figura 14, dessa forma apenas registros com “*Status = Ativo*” serão incluídos. Conforme ilustrado na Figura 15, é possível nomear o filtro (1), definir a condição de inclusão baseada na coluna *Evasão = No* (2), ajustar os conectores lógicos *OR* (OU) (3) e *AND* (E) (4), além de finalizar a configuração clicando em *Salvar* (5). Filtros podem ser aplicados a componentes específicos, a páginas ou ao relatório inteiro, sendo sempre gerenciados no painel de propriedades.

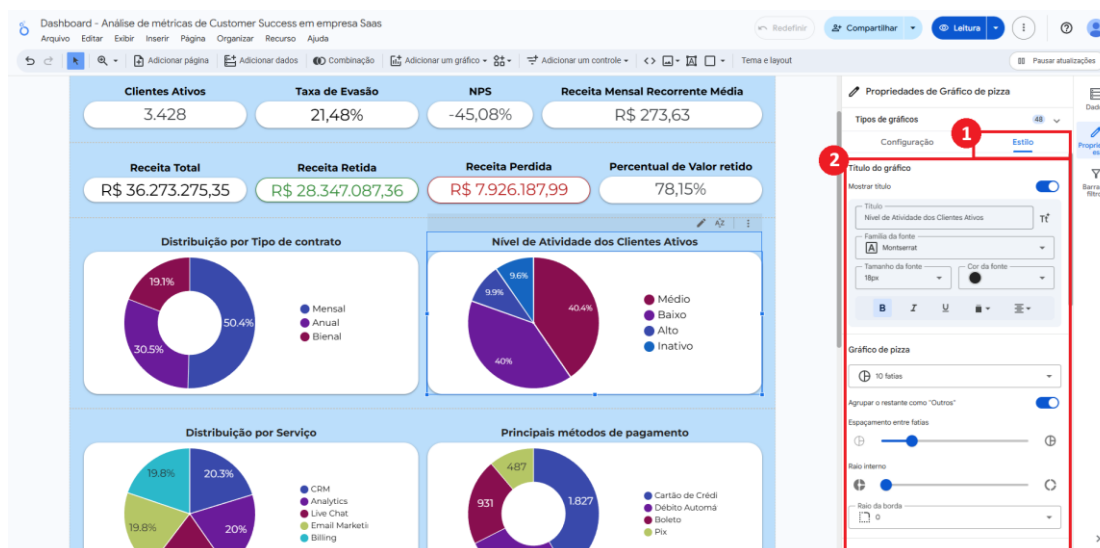
Figura 15 – Criação de filtro no *Looker Studio*



Fonte: *Looker Studio*, 2025, on-line.

5. Ajustar estilo e rótulos. No painel *Style/Estilo* (1) da Figura 16, é possível configurar a apresentação visual do gráfico, incluindo a habilitação de rótulos e legenda, a definição de exibição em percentual e, caso desejado, a alteração do formato para donut (anel) (2). Conforme ilustrado na Figura 16, também é possível ajustar o título do gráfico (2), escolher tipografia, cores e dimensões, além de definir espaçamento entre fatias e o raio interno.

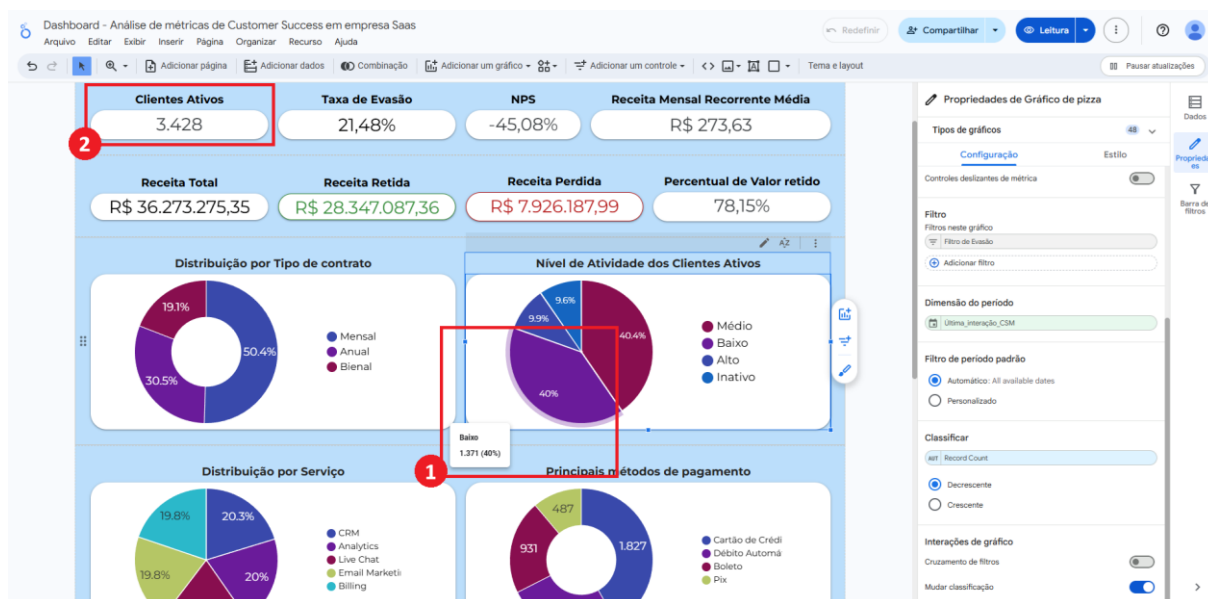
Figura 16 – Configuração de estilo do gráfico de pizza no *Looker Studio*



Fonte: *Looker Studio*, 2025, on-line.

6. Validar o resultado. Pode-se confirmar se a soma dos registros por Uso corresponde ao total de clientes ativos e se os percentuais exibidos são coerentes (aproximadamente 100%). Conforme ilustrado na Figura 17, ao posicionar o cursor sobre uma fatia do gráfico (1), é exibida a informação de categoria com percentual e quantidade associada, substituindo o valor absoluto quando configurado para exibir em percentual. Nesse caso, a soma das fatias totalizou 3.428, número que corresponde exatamente à quantidade de clientes ativos indicada no indicador superior (2). Além disso, títulos, legendas e cores devem ser revisados de modo a assegurar legibilidade e consistência visual com o restante do relatório.

Figura 17 – Validação da soma de registros no gráfico de nível de atividade



Fonte: Looker Studio, 2025, on-line.

7. Escolher o gráfico.

Para a representação da métrica de nível de atividade dos clientes, adotou-se o gráfico de pizza, dada sua capacidade de oferecer uma leitura imediata de proporções quando existem poucas categorias bem definidas — neste caso, quatro níveis de uso (Alto, Médio, Baixo e Inativo). Essa escolha favorece a comunicação executiva, uma vez que permite identificar rapidamente a distribuição do mix de atividade da base.

Cabe ressaltar que, para diferentes métricas, tipos distintos de gráficos podem e devem ser utilizados, considerando sempre o objetivo da análise e a clareza na comunicação dos resultados. Métricas temporais, por exemplo, tendem a ser melhor representadas por gráficos de linhas ou séries temporais; já comparações absolutas entre grupos podem ser mais bem evidenciadas por gráficos de barras ou colunas. A própria documentação de referência do Looker Studio recomenda o gráfico de pizza especificamente para situações em que se busca destacar a relação relativa entre categorias a partir de uma única dimensão e métrica.

4.3.2 Aplicação dos passos às demais métricas

O procedimento foi reproduzido para as demais métricas consideradas neste estudo, a saber, de acordo com a Tabela 3.

Tabela 3 – Métricas analisadas, fórmulas e finalidades

Análise	Gráfico	Dimensão	Métrica/Fórmula
Número de Clientes Ativos	<i>Scorecard</i>	Não Aplicável	COUNT(CASE WHEN Evasão = "No" THEN 1 END)
Taxa de Churn	<i>Scorecard</i>	Não Aplicável	SUM(CASE WHEN Evasão = "Yes" THEN 1 ELSE 0 END) / COUNT(Evasão)
Net Promoter Score (NPS)	<i>Scorecard</i>	Não Aplicável	((COUNT(CASE WHEN NPS >= 9 THEN 1 END) / COUNT(NPS)) - (COUNT(CASE WHEN NPS <= 6 THEN 1 END) / COUNT(NPS)))
Receita Mensal Recorrente Média (RMRM)	<i>Scorecard</i>	Não Aplicável	AVG(Cobrança_Mensal)
Receita Total	<i>Scorecard</i>	Não Aplicável	Valor_Total
Receita Retida	<i>Scorecard</i>	Não Aplicável	SUM(CASE WHEN Evasão = "No" THEN Valor_Total ELSE 0 END)
Receita Perdida	<i>Scorecard</i>	Não Aplicável	SUM(CASE WHEN Evasão = "Yes" THEN Valor_Total ELSE 0 END)
Percentual de Valor Retido	<i>Scorecard</i>	Não Aplicável	(SUM(CASE WHEN Evasão = "No" THEN Valor_Total ELSE 0 END) / SUM(Valor_Total))
Distribuição por Tipo de Contrato	<i>Donut</i>	Tipo_de_Contrato	<i>Record Count</i>
Principais Método de Pagamento	<i>Donut</i>	Método_de_Pagamento	<i>Record Count</i>
Nível de Atividade dos Clientes ativos	Pizza	Uso	<i>Record Count</i>
Distribuição por Serviço Contratado	Pizza	Serviço	<i>Record Count</i>

Fonte: Autor.

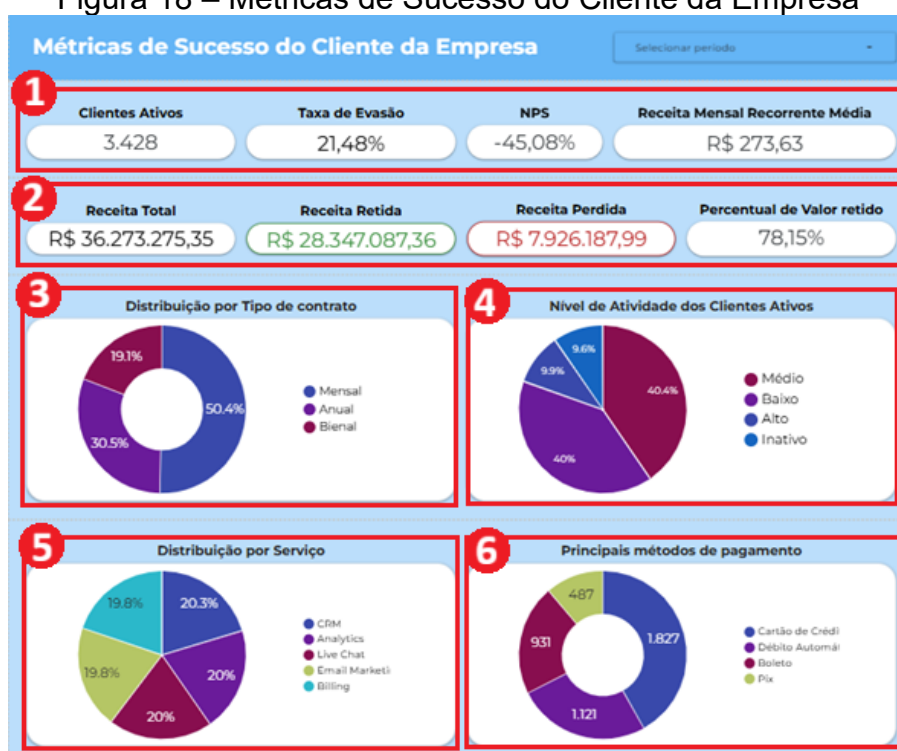
Dessa forma, os procedimentos descritos nesta seção consolidaram a construção de um processo de BI voltado à análise de métricas de *Customer Success* em ambientes SaaS, permitindo simulações realistas, reprodutibilidade e aplicação prática dos conceitos teóricos discutidos.

Cada gráfico será apresentado na seção seguinte, acompanhado da respectiva interpretação, de forma a mostrar a relevância do indicador para o monitoramento do desempenho dos clientes e para a saúde financeira da organização.

4.4 Análise do Dashboard

A aplicação de *Business Intelligence* (BI) possibilitou a consolidação e visualização das principais métricas de *Customer Success* da empresa SaaS em estudo. A escolha dos indicadores e dos gráficos apresentados foi pautada na literatura de gestão de clientes (ALVES, 2021; STEINMAN; MURPHY; MEHTA, 2021; SANTOS; GIBERTONI, 2022), considerando tanto o acompanhamento da saúde da base quanto a mensuração do impacto financeiro da retenção e evasão. Foram utilizados *scorecards* para destacar indicadores-chave de desempenho (KPIs), por fornecerem leitura direta de valores absolutos e percentuais. Já os gráficos de *pizza/donut* foram empregados para demonstrar distribuições proporcionais, como contratos, serviços e métodos de pagamento, enquanto a análise de engajamento foi representada por gráficos de composição de níveis de uso, ambos as formas de visualização podem ser vistas na Figura 18 que mostra a visualização completa do *Dashboard*.

Figura 18 – Métricas de Sucesso do Cliente da Empresa



Fonte: Autor, on-line.

Na visão geral apresentada no *dashboard* (Figura 18), identificou-se que a empresa conta com 3.428 clientes ativos visto no *scorecard* de Clientes Ativos (1), valor que serve de referência para as demais análises. A taxa de evasão atingiu 21,48% visto no *scorecard* de Taxa de Evasão (1), número elevado para empresas SaaS e que reforça a importância de estratégias de retenção. O NPS, por sua vez,

apresentou resultado de -45,08% visto no *scorecard* de NPS (1), indicando predominância de detratores em relação a promotores e evidenciando insatisfação com a experiência oferecida. A Receita Mensal Recorrente Média (RMRR) foi de R\$ 273,63 visto no *scorecard* de receita mensal recorrente média (1), sinalizando baixo ticket médio mensal quando comparado à receita total, o que sugere espaço para ações de *upsell* e *cross-sell*.

No âmbito financeiro, a análise revelou uma receita total de R\$ 36.273.275,35 visto no *scorecard* de Receita Total (2), dos quais R\$ 28.347.087,36 foram retidos visto no *scorecard* de Receita Retida (2) e R\$ 7.926.187,99 foram perdidos em função da evasão visto no *scorecard* de Receita Perdida (2). Assim, o percentual de valor retido foi de 78,15% visto no *scorecard* de Percentual de Valor Retido (2). Esse resultado mostra que a evasão impacta de forma proporcional tanto no número de clientes quanto na receita, sem concentração significativa de churn em clientes de alto valor.

A distribuição por tipo de contrato mostrou que 50,4% da base utiliza planos mensais, enquanto 30,5% estão em planos anuais e 19,1% em bienais visto no gráfico de pizza de Distribuição por Tipo de contrato (3). O predomínio de contratos de curto prazo aumenta a vulnerabilidade ao churn, indicando a necessidade de estímulos à contratação de planos mais longos. Em relação ao nível de atividade, verificou-se que 40,4% dos clientes foram classificados como de uso médio, 40% como de uso baixo, 9,6% como inativos e apenas 9,9% como de uso alto visto no gráfico de pizza de Distribuição por Serviço (5). Esse cenário revela baixa adesão plena às funcionalidades oferecidas, o que pode estar diretamente relacionado à taxa de evasão observada.

A distribuição por serviço contratado evidenciou equilíbrio apresentado na Figura 18, com todos os cinco serviços (*CRM, Analytics, Live Chat, Email Marketing* e *Billing*) situando-se entre 19,8% e 20,3% da base visto no gráfico de pizza de Nível de atividade de todos os clientes (5). Esse balanceamento sugere que não há concentração em um único produto, mas também abre espaço para estratégias de aumento de valor agregado por meio da combinação de serviços. Por fim, a análise dos métodos de pagamento mostrou predominância do cartão de crédito 1.827 clientes, seguido por débito automático 1.121 clientes, boleto 931 e Pix 487 clientes visto no gráfico de pizza de Principais métodos de pagamento (6). A predominância de meios automáticos de pagamento é positiva, pois reduz inadimplência e churn involuntário, mas a presença significativa de boletos pode indicar risco maior de cancelamentos e falhas de cobrança.

De forma integrada, os resultados obtidos demonstram que a empresa apresenta alto risco de evasão, engajamento limitado dos clientes e insatisfação expressiva refletida no NPS negativo, embora mantenha uma receita relativamente estável e distribuída entre diferentes serviços. Tais achados reforçam a necessidade de atuação estratégica do time de *Customer Success*, tanto no aumento da retenção quanto na expansão do valor médio por cliente, temas que serão aprofundados na próxima seção por meio de planos de ação direcionados.

5 Plano de Ação

A análise das métricas evidenciou fragilidades importantes, como a elevada taxa de evasão, o baixo engajamento de clientes e a predominância de contratos mensais, além de um Net Promoter Score negativo. Para enfrentar esses desafios, elaboraram-se planos de ação que visam apoiar a área de *Customer Success* na retenção de clientes, no aumento da receita recorrente e na melhoria da experiência do usuário. Tais planos foram estruturados considerando a importância da cultura organizacional orientada ao cliente e do uso do Business Intelligence como ferramentas estratégicas para decisões assertivas.

Conforme Dallabrida (2023), o sucesso do cliente deve ser entendido como uma filosofia organizacional que perpassa todos os setores da empresa, alinhando práticas internas ao objetivo de gerar valor sustentável e competitivo. Essa visão reforça que os planos de ação aqui apresentados não podem ser isolados, mas sim integrados à cultura organizacional. Ao mesmo tempo, o monitoramento sistemático dos indicadores por meio de BI é fundamental, pois permite a coleta, análise e acompanhamento contínuo de dados, transformando-os em informações úteis para a tomada de decisão (BRAGHITTONI, 2017 apud SANTOS; GIBERTONI, 2022).

Nesse contexto, destaca-se primeiramente a necessidade de reduzir o churn. Para isso, propõe-se a implementação de sistemas de pontuação de saúde do cliente (*health score*), combinando métricas de uso, satisfação e histórico de relacionamento. A detecção precoce de clientes em risco permitirá ações preventivas, como contatos proativos e planos de recuperação individualizados. Essa prática está em consonância com a literatura de Customer Success, que aponta o monitoramento e a intervenção preventiva como elementos centrais para a diminuição da evasão (STEINMAN; MURPHY; MEHTA, 2021 apud DALLABRIDA, 2023).

Outro eixo fundamental está na melhoria da experiência do cliente, refletida no NPS. Recomenda-se instituir um programa estruturado de Voz do Cliente, que permita a coleta sistemática de feedbacks de detratores e promotores, gerando insumos para ações de melhoria em produto, suporte e comunicação. Além disso, o aprimoramento do processo de *onboarding*, com materiais interativos e treinamentos iniciais, pode elevar rapidamente a percepção de valor, contribuindo para a fidelização. Quanto ao engajamento, os dados mostraram que a maioria dos clientes apresenta uso médio ou baixo dos serviços. Para reverter esse cenário, é necessário investir em educação contínua do cliente, por meio de academias digitais, trilhas de capacitação e segmentação de campanhas de estímulo ao uso por serviço contratado. O fortalecimento do papel do Customer Success Manager, que atua de forma consultiva e especializada, também se mostra essencial para aproximar a empresa dos resultados esperados pelos clientes (DALLABRIDA, 2023).

No aspecto financeiro, a predominância de contratos mensais torna a empresa mais suscetível à evasão. Assim, sugerem-se estratégias de incentivo à migração para contratos anuais e bienais, como descontos, bônus ou pacotes integrados de serviços. O objetivo é aumentar a previsibilidade de receita e elevar o percentual de valor retido, em linha com o que a literatura de BI aponta sobre a

importância de indicadores para sustentar a competitividade de longo prazo (SANTOS; GIBERTONI, 2022).

Outro ponto identificado foi o risco associado ao uso do boleto como método de pagamento, que representa maior probabilidade de inadimplência. A ação recomendada é promover a migração para meios automáticos, como cartão de crédito ou débito, complementada por fluxos de cobrança automatizados (*dunning*) e pelo uso de Pix como alternativa de regularização imediata.

Por fim, cabe ressaltar que a efetividade desses planos dependerá do acompanhamento contínuo dos indicadores já estruturados no *dashboard*. A redução da taxa de evasão para patamares inferiores a 15% ao ano, a recuperação do NPS para valores positivos, o aumento da proporção de clientes de uso alto e a expansão dos contratos de longo prazo são metas que devem ser monitoradas regularmente. Como destacam Santos e Gibertoni (2022), apenas com a coleta, análise e monitoramento sistemático de dados é possível ajustar os planos de ação de forma dinâmica, garantindo que as decisões sejam ágeis, assertivas e sustentadas em informações confiáveis.

Nesse sentido, a Tabela 4 sintetiza os principais problemas identificados, as ações propostas, as métricas associadas e as metas esperadas, facilitando a revisão e acompanhamento dos planos pela gestão.

Tabela 4 – Planos de ação para melhoria dos indicadores de Customer Success

Problema Identificado	Ação Proposta	Métrica Associada	Meta Esperada
Alta taxa de churn (evasão)	Implementar <i>health score</i> , contatos proativos e planos de recuperação individual	Churn Rate	Reduzir para menos de 15% ao ano
NPS negativo	Implantar programa Voz do Cliente, feedback estruturado e melhorias no <i>onboarding</i>	Net Promoter Score (NPS)	Tornar o NPS positivo (> 0)
Baixo engajamento dos clientes	Oferecer trilhas de capacitação, campanhas segmentadas e atuação ativa do CSM	Nível de Uso (Engajamento)	Aumentar a proporção de clientes engajados
Predominância de contratos curtos	Incentivar migração para contratos anuais/bienais com benefícios	Tipo de Contrato	Ampliar percentual de contratos longos

Risco de inadimplência com boletos	Promover migração para cartão, débito, Pix e implementar <i>dunning</i> automatizado	Método de Pagamento	Reduzir inadimplência
------------------------------------	--	---------------------	-----------------------

Fonte: Adaptado de Dallabrida, 2023; Santos e Gibertoni, 2022; Steinman, Murphy e Mehta, 2021.

6 Conclusão

O desenvolvimento deste trabalho permitiu compreender como a aplicação de Business Intelligence pode apoiar a análise e a gestão de métricas estratégicas de Customer Success em empresas SaaS. A construção de um dataset sintético viabilizou simulações próximas da realidade organizacional, possibilitando a avaliação de indicadores como churn rate, lifetime value, receita recorrente mensal e engajamento. Os resultados mostram fragilidades relevantes, como a alta taxa de evasão, o baixo nível de utilização dos serviços e a insatisfação refletida no NPS negativo, aspectos que comprometem tanto a retenção quanto a expansão da base de clientes.

Diante desse cenário, os planos de ação propostos ressaltaram a necessidade de atuação estratégica do time de *Customer Success*, incluindo o monitoramento contínuo dos indicadores, a implementação de sistemas de pontuação de saúde do cliente, o fortalecimento do onboarding e da educação continuada, além do incentivo a contratos de longo prazo e da redução do uso de boletos como método de pagamento.

Portanto, este estudo evidencia que a integração entre métricas de *Customer Success* e ferramentas de *Business Intelligence* contribui significativamente para decisões mais assertivas e alinhadas aos objetivos de retenção e fidelização. Embora baseado em dados sintéticos, o modelo aqui proposto pode servir de referência para a aplicação em cenários reais, reforçando a importância da cultura organizacional orientada ao cliente e do uso de dados como suporte à competitividade sustentável no mercado SaaS.

Adicionalmente, o processo metodológico adotado neste estudo — com a aplicação do ciclo de BI (geração, preparação, análise, visualização e ação) — mostrou ser uma abordagem eficiente e didática para projetos de análise de dados voltados ao apoio da gestão estratégica. A utilização de ferramentas acessíveis, como R e *Looker Studio*, evidencia que soluções de BI podem ser implementadas com baixo custo por pequenas e médias empresas, desde que alinhadas a uma cultura orientada a dados.

Por fim, espera-se que este trabalho contribua não apenas como um exercício técnico-acadêmico, mas como uma base para futuras aplicações práticas em empresas reais, bem como para estudos posteriores sobre o papel do Business Intelligence na experiência e fidelização do cliente. A replicabilidade da abordagem

aqui apresentada amplia seu valor como modelo de apoio à tomada de decisão em contextos digitais e orientados por métricas.

Referências

ALVES, J. **Métricas SaaS: as 10 métricas mais importantes para seu negócio**. São Paulo: SaaSholic, 2021. Disponível em: <https://saasholic.com/metricas-saas>. Acesso em: 23 mar. 2025.

CARVALHO, L. R. **Desenvolvimento de dashboard em Power BI para análise de performance de projetos de BESS**. 2019. Trabalho de Conclusão de Curso (Graduação em Engenharia de Energia) – Universidade Federal de Itajubá, Itajubá, 2019.

CDLBH (CÂMARA DE DIRIGENTES LOJISTAS DE BELO HORIZONTE). **Google Data Studio: conheça a ferramenta gratuita de BI**. Belo Horizonte: CDLBH, 2019. Disponível em: <https://cdlbh.com.br>. Acesso em: 20 mar. 2025.

DAMASCENO, Brunno Phelipe Oliveira; ALCALÁ, Symone Gomes Soares. **Desenvolvimento de uma ferramenta de Business Intelligence para apresentação de resultados financeiros empresariais**. *Revista Produção Online*, Florianópolis, v. 25, n. 1, e-5343, 2025. DOI: 10.14488/1676-1901.v25i1.5343.

DALLABRIDA, Laís Cristini. **A importância da cultura centrada no sucesso do cliente: um estudo sobre o alinhamento da cultura organizacional no setor de Customer Success de empresas altamente competitivas**. 2023. Trabalho de Conclusão de Curso (Bacharelado em Administração) — Universidade Federal de Santa Catarina, Centro Socioeconômico, Departamento de Ciências da Administração, Florianópolis, 2023.

GOOGLE CLOUD. **O que é o Looker Studio?** Mountain View: Google, 2023. Disponível em: <https://cloud.google.com/looker-studio>. Acesso em: 21 mar. 2025.

GOOGLE. **Looker Studio: Tutorial — Add charts to your report**. 2025. Disponível em: <https://cloud.google.com/looker/docs/studio/tutorial-add-charts-to-your-report>. Acesso em: 19 julho 2025a. Google Cloud

GOOGLE. **Looker Studio: Pie chart reference**. 2025. Disponível em: <https://cloud.google.com/looker/docs/studio/pie-chart-reference>. Acesso em: 19 julho 2025b. Google Cloud

GOOGLE. **Looker Studio: COUNT (função de contagem)**. 2025. Disponível em: <https://cloud.google.com/looker/docs/studio/count>. Acesso em: 19 julho 2025c. Google Cloud

GOOGLE. **Looker Studio: Create, edit, and manage filter properties**. 2025. Disponível em: <https://cloud.google.com/looker/docs/studio/create-edit-and-manage-filter-properties>. Acesso em: 19 julho 2025d.

IBM. **O que é business intelligence (BI)?** Disponível em: <https://www.ibm.com/br-pt/topics/business-intelligence>. Acesso em: 15 mar. 2025.

JENGAL. **What is SaaS Software?** Disponível em: <https://www.jengal.com/blog/what-is-saas-software>. Acesso em: 15 mar. 2025.

MELL, P.; GRANCE, T. **The NIST Definition of Cloud Computing**. Gaithersburg: U.S. Department of Commerce, 2011. (NIST Special Publication 800-145). Disponível em: <https://nvlpubs.nist.gov/nistpubs/Legacy/SP/nistspecialpublication800-145.pdf>. Acesso em: 21 mar. 2025.

MORAES, C. R. **Power BI: modelagem e visualização de dados**. São Paulo: Novatec, 2020.

SANTOS, V. L.; GIBERTONI, D. **Os impactos do Business Intelligence para tomada de decisões**. Revista Interface Tecnológica, Taquaritinga, v. 19, n. 2, p. 258-267, 2022. DOI: 10.31510/infa.v19i2.1524.

SKOK, D. **SaaS Metrics 2.0: a guide to measuring and improving what matters**. Boston: For Entrepreneurs, 2021. Disponível em: <https://www.forentrepreneurs.com>. Acesso em: 22 mar. 2025.

STEINMAN, N.; MURPHY, R.; MEHTA, N. **Customer Success: como as empresas inovadoras descobriram que a melhor forma de aumentar a receita é garantir o sucesso dos clientes**. São Paulo: Autêntica Business, 2021.

ROMERO, C. A. T.; ORTIZ, J. H.; KHALAF, O. I.; RÍOS PRADO, A. **Business Intelligence: Business Evolution after Industry 4.0**. Sustainability, Basel, v. 13, n. 18, p. 10026, 2021. DOI: <https://doi.org/10.3390/su131810026>.