

# Modelagem de Monetização de Jogos para Dispositivos Móveis

## *Monetization Modeling for Mobile Games*

Rafael Batista dos Santos, Geraldo Bonorino Xexéo

<sup>1</sup> LUDS - Laboratório de Ludologia, Engenharia e Simulação  
Programa de Engenharia de Sistemas e Computação  
COPPE - Universidade Federal do Rio de Janeiro  
Avenida Horácio Macedo, 2030, CT, Bloco H, sala 319, Rio de Janeiro, RJ - Brasil

{rbatista, xexeo}@cos.ufrj.br

**Abstract.** *This study developed a System Dynamics model to explore monetization scenarios in mobile games. Through a case study, the model demonstrates how strategic adjustments to operational variables can significantly affect profit, emphasizing the importance of adaptive strategies based on the specific characteristics of each application and its market position. The results underscore the potential of System Dynamics as an effective strategic tool for decision-making in the dynamic mobile application market.*

**Keywords** *Dynamic systems, Mobile Applications, Scenario analysis, Monetization, Simulation, Mobile games.*

**Resumo.** *Este estudo desenvolveu um modelo de System Dynamics para investigar cenários de monetização em jogos de dispositivos móveis. Por meio de um estudo de caso, o modelo demonstra como ajustes estratégicos em variáveis operacionais podem influenciar significativamente o lucro, enfatizando a importância de estratégias adaptativas conforme as características específicas de cada aplicativo e sua posição no mercado. Os resultados sublinham o potencial do System Dynamics como uma ferramenta estratégica eficaz para a tomada de decisões no dinâmico mercado de aplicativos móveis.*

**Palavras-Chave** *Sistemas dinâmicos, Aplicativos móveis, Análise de cenários, Monetização, Simulação, Jogos móveis.*

## 1. Introdução

O papel crescente dos aplicativos em nossas vidas diárias é inegável. Segundo relatórios de mercado, dispositivos móveis representaram mais de 65% do *market share* de tráfego online em 2023, com uma queda correspondente no uso de *desktops* [SimilarWeb 2024]. Além disso, os usuários de aplicativos móveis estão cada vez mais engajados, com mais de 257 bilhões de downloads e uma média de 5 horas de uso diário por usuário em 2023. 32,4% usa a internet para jogar. Desses, jogos hipercasuais representam 27% dos downloads [data.ia 2024]. No entanto, apesar da abundância de dados e da importância dos aplicativos móveis, persiste uma lacuna no entendimento de como variáveis externas e internas interagem e influenciam o mercado de aplicativos.

Esta pesquisa identifica essa lacuna e propõe uma abordagem de modelagem para preencher essa necessidade. O objetivo principal é desenvolver e testar um modelo de

*System Dynamics* [Forrester 1961] para analisar cenários de vendas e funcionamento de empresas de aplicativos de jogos móveis. Este modelo permitirá aos gestores e “game designers” antecipar cenários futuros e tomar decisões informadas para direcionar estrategicamente as operações e o marketing de seus aplicativos.

Este artigo está organizado da seguinte maneira: A Seção 2 descreve o método proposto, delineando as etapas seguidas na modelagem. A Seção 3 detalha a execução de um experimento com um jogo freemium para testar o modelo proposto, discute a implementação e os testes do modelo, incluindo uma comparação com um modelo de referência e uma análise de sensibilidade para explorar a sua robustez. Finalmente, a Seção 4 conclui o trabalho com um resumo dos resultados, as implicações práticas do estudo e sugestões para pesquisas futuras.

## 2. Referencial Teórico

System Dynamics (SD) é uma técnica de modelagem matemática desenvolvida por Jay W. Forrester no MIT na década de 1950 para analisar sistemas complexos usando variáveis como estoques, fluxos e constantes [Forrester 1961]. Trabalhos influentes no campo, como os de Meadows [Meadows et al. 1972] e Richardson [Richardson 2011], assim como o estudo de Ribeiro sobre o crescimento e declínio de websites [Ribeiro 2014], fundamentam a metodologia aplicada neste estudo.

Na área de vendas e marketing, conceitos como o funil de vendas e a hierarquia dos efeitos oferecem uma estrutura para entender a progressão do cliente desde a consciência até a compra [Doyle 2016] [Endeavor 2021], [Lewis 1908], [Wijaya 2015].

A aplicação proposta nesse trabalho apresenta uma abordagem inovadora de utilização de System Dynamics em cenários de aplicativos móveis, incorporando esses princípios estabelecidos em um novo contexto de análise e previsão.

## 3. Método

O modelo proposto seguirá as etapas definidas pela equipe do Massachusetts Institute of Technology (MIT), explicada em detalhes no livro *Elements of System Dynamics Method* [Randers 1980, p.117-139], no qual o processo de modelagem de um Sistema Dinâmico é delineado em quatro etapas principais descritas a seguir: Conceituação, Formulação, Teste e Implementação.

### 3.1. Conceituação do Modelo

A fase inicial do processo é dedicada à construção de uma fundação sólida para o modelo, envolvendo uma compreensão profunda do problema e a definição clara de seus objetivos, como discutido a seguir.

#### 3.1.1. Propósito do Modelo

Ao considerar o desenvolvimento de um aplicativo como um investimento, foi adotada uma perspectiva de administração financeira visando a maximização do seu valor de mercado. Para isso, a aplicação de técnicas de análise e avaliação de projetos é essencial. Partindo do princípio de que “sempre que avaliamos uma decisão de negócios, o tamanho,

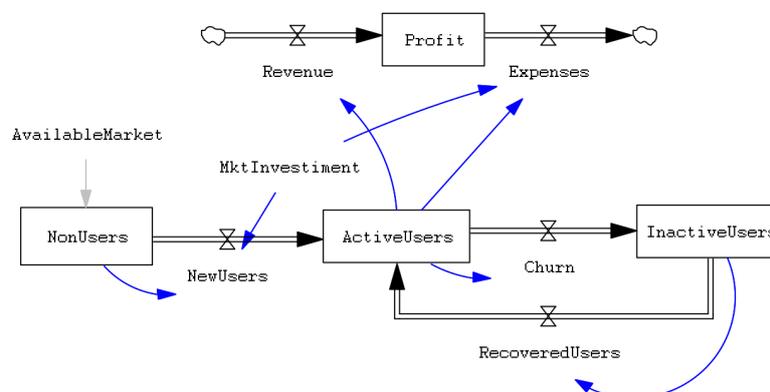
o tempo e o risco dos fluxos de caixa são, sem dúvida, as coisas mais importantes a serem consideradas” [Ross et al. 2013, p.3], o modelo proposto visa aprofundar a compreensão sobre o comportamento dos usuários de aplicativos móveis, considerando a avaliação do impacto de diferentes estratégias, abrangendo monetização, marketing e desenvolvimento de produto.

### 3.1.2. Modelo de referência

O modelo proposto baseia-se no trabalho desenvolvido no artigo “Modeling and predicting the growth and death of membership-based websites” [Ribeiro 2014], que examina o crescimento dos usuários ativos diários (DAU) em sites. Este estudo sugere uma abordagem para descrever a evolução dos usuários, classificando-os em membros ativos, inativos ou não membros. Identifica-se dois tipos de crescimento: um impulsionado por marketing pago e campanhas de mídia, e outro decorrente de divulgação boca a boca. O trabalho também diferencia os sites em auto-sustentáveis versus insustentáveis. Segundo o artigo, o crescimento viral tende a seguir uma curva exponencial, enquanto o impulsionado por marketing pago apresenta uma forma convexa. Adicionalmente, o modelo de referência mostra que os usuários ativos de produtos sustentáveis exibem um padrão em curva S, característico de um crescimento logístico.

### 3.1.3. Mecanismos Básicos

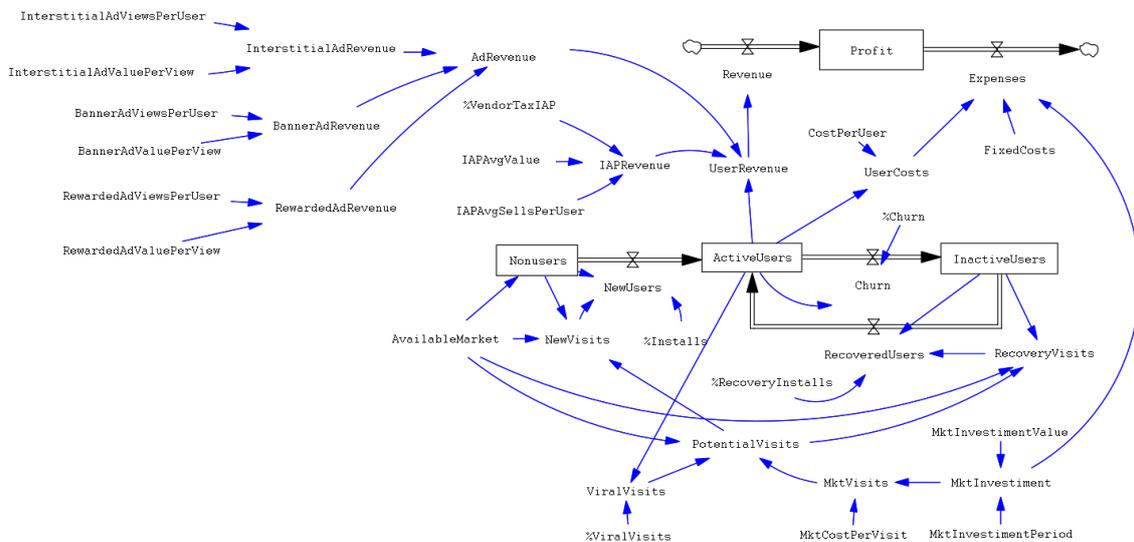
A fim de elucidar as interações fundamentais e os processos que governam o comportamento de aplicativos, foi feito um modelo de mecanismos básicos que ilustra dois fluxos interconectados: o fluxo da jornada de usuários e o fluxo de caixa operacional. O fluxo de caixa operacional do modelo proposto considera somente os montantes relacionados à operação do aplicativo. A estrutura de monetização foi dividida em custos, fixos e variáveis, e despesas. O diagrama do modelo pode ser visto na Figura 1.



**Figura 1. Diagrama dos Mecanismos Básicos.**

## 3.2. Formulação das Equações do Modelo

Nessa seção, será feita a elaboração das equações necessárias para a representação do modelo de referência e demais objetivos, considerando variáveis possíveis de serem estimadas. O diagrama do modelo completo pode ser visto na Figura 2.



**Figura 2. Modelo Completo.**

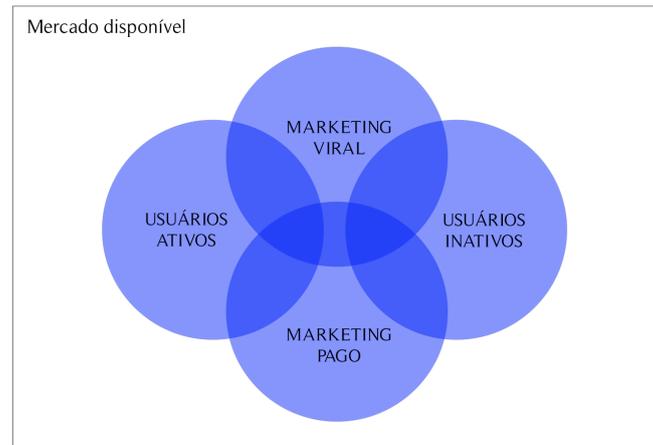
Primeiramente, os não usuários (*NonUsers*), caracterizados por pessoas que ainda não demonstraram interesse no aplicativo, começam com valor igual a todo o mercado disponível (*AvailableMarket*), ou seja, igual ao conjunto de consumidores que possuem renda, interesse e acesso ao aplicativo [Kotler 2018, p.93-95]. Esse número diminui conforme as pessoas visitam a página do aplicativo e o instalam. Para aplicativos Android, essas visitas correspondem ao total de usuários que acessaram a página “Detalhes do App” da “Play Store”.

Desse modo, o fluxo de novos usuários (*NewUsers*), que representa aqueles que passaram de não usuários para usuários ativos, divide-se em dois componentes: as visitas à página do aplicativo, *NewVisits*, e a subsequente decisão de instalação, *%Installs*. Portanto, *NewUsers* é calculado pela multiplicação de *NewVisits* por *%Installs*.

A decisão de instalar um aplicativo depende de vários fatores, como o tipo de aplicativo, o preço, e a qualidade percebida do aplicativo. Esses fatores podem ser estimados diretamente a partir dos dados históricos, do mercado ou do aplicativo em questão. Neste trabalho a taxa de instalação, *%Installs*, é uma variável estimada diretamente dos dados de mercado.

Uma dificuldade ao calcular *NewVisits* é que os efeitos marketing pago e da propagação viral podem afetar não somente os não usuários, mas todo o mercado disponível. A fim de facilitar o entendimento, essas relações estão representadas no diagrama de Venn da Figura 3. O diagrama ilustra que o marketing viral e pago podem simultaneamente influenciar tanto a instalação de novos usuários quanto de usuários recuperados, assim como recair sobre usuários que já são ativos.

Por causa dessa dificuldade, são estimadas, primeiramente, as visitas potenciais, considerando todo o mercado disponível impactado. Essas são obtidas assumindo que as probabilidades de uma visita ser motivada por uma campanha de marketing ou pelo boca a boca são independentes e não exclusivas. Com isso, o número total de pessoas atingidas simultaneamente por ambos os efeitos é calculado por  $PotentialVisits = ViralVisits \cup MktVisits = ViralVisits + MktVisits - \frac{ViralVisits \times MktVisits}{AvailableMarket}$ . A subtração final



**Figura 3. Diagrama de Venn para marketing pago e viral.**

ajusta a sobreposição na contagem de visitas de marketing pago e viral.

Finalmente, as novas visitas são calculadas multiplicando o efeito de marketing, representado por `PotentialVisits`, pelos usuários que ainda não conhecem o aplicativo (`Nonusers / AvailableMarket`).

A fim de permitir a análise de campanhas de marketing em períodos restritos, o investimento em marketing é dividido entre `MktInvestmentPeriod`, que representa o número de períodos (meses) iniciais onde a campanha será realizada e `MktInvestmentvalue`, que representa o valor total investido.

Churn, ou taxa de cancelamento, é a proporção de clientes que abandonam um serviço em relação ao total de clientes ativos, serve como um termômetro para medir a saúde e a sustentabilidade de um negócio [Salesforce 2021]. Este modelo quantifica o churn com base no número de usuários atuais e na taxa de churn, `%Churn`, estimada a partir de dados históricos.

As visitas de usuários recuperados (`RecoveredVisits`) são aqueles que voltam a usar o aplicativo após ter cessado o seu uso. De maneira similar à novos usuários, são calculadas filtrando as visitas potenciais, `PotentialVisits`, pela proporção de pessoas que são usuários inativos (`InactiveUsers / AvailableMarket`). Por fim, os usuários recuperados (`RecoveredUsers`) são calculados de maneira similar à `NewUsers`, como a multiplicação de `RecoveredVisits` e `%RecoveredInstalls`.

Os modelos de monetização prevalentes em jogos freemium são os de compras dentro do aplicativo (In App Purchases) e anúncios (Ads) [Google Play 2019]. A plataforma do Google AdMob [Google 2024] oferece uma série de tipos de anúncios, dentre os quais são relevantes para este artigo: **Banner**: Os blocos de anúncios de banner exibem anúncios retangulares que ocupam uma parte do layout de um app; **Intersticial**: Os blocos de anúncios intersticiais exibem anúncios de página inteira no aplicativo; e **Premiado**: Os blocos de anúncios premiados permitem que os usuários joguem, respondam a pesquisas ou assistam vídeos para ganhar recompensas no app, como moedas, vidas extras ou pontos.

Assim, a Receita de Anúncios ( $AdRevenue$ ) é calculada como a multiplicação da média de Ads por usuário ( $AdAvgUser$ ) pelo valor médio ganho por Ad ( $AdAvgValue$ ). Note que o  $AdRevenue$  pode ser diferente para cada tipo de anúncio (Interstitial, Rewarded e Banner, etc.), nestes casos, a fórmula da receita deve ser dividida entre os respectivos tipos.

A monetização por meio de Ads oferece uma forma de gerar receita sem exigir pagamentos diretos dos usuários. Por outro lado, In App Purchases (IAP), ou compras internas, referem-se à opção dos usuários de realizar compras dentro do jogo. A receita de IAP ( $IAPRevenue$ ) é calculada como a média de compras IAP por usuário ( $IAPAvgUser$ ) multiplicado pelo valor médio por IAP ( $IAPAvgValue$ ) e descontando a taxa de operação da plataforma ( $\%VendorTaxIAP$ ).

Por fim, a receita de Usuários ( $UserRevenue$ ) é a soma das receitas individuais relacionadas a usuários multiplicado pelos usuários ativos. Os custos relacionados aos usuários são calculados como o número de usuários ativos ( $ActiveUsers$ ) multiplicado pelo custo por usuário ( $CostPerUser$ ). Já as despesas totais são a soma das despesas de marketing com as baseadas em usuários e despesas fixas.

## 4. Experimento

Para validar o modelo proposto, foi conduzido um estudo de caso em um jogo freemium para Android, monetizado por anúncios e compras dentro do aplicativo (IAP), destinado ao mercado brasileiro. As variáveis do modelo são baseadas em parte no pós-mortem do jogo Jelly Splash [Seufert 2014] e em dados da Play Store, coletadas pelo Google Play Console, para jogos casuais no Brasil de fevereiro de 2024, onde foram coletadas estatísticas mensais como a mediana das medianas e dos quartis. Dados adicionais são provenientes de relatórios de mercado.

Os valores monetários foram coletados em dólar e a simulação foi executada considerando um passo de um mês, ao longo de dois anos, usando o software Vensim [Vensim 2023].

### 4.1. Estimação dos parâmetros

Dados da PNAD Contínua [Instituto Brasileiro de Geografia e Estatística (IBGE) 2023] de 2022 mostram que 161,6 milhões de brasileiros acima de 10 anos utilizam a internet, principalmente via celular, representando 98,9%. Considerando que 32,4% usam a internet para jogar e que 27% dos downloads são de jogos hipercasuais. A partir desses dados, o mercado disponível ( $Available\ Market$ ) pode ser estimado pelo método de proporção em cadeia, descrito por Kotler (2018, p.95), multiplicando o número base pelos percentuais de ajuste de cada fator identificado, resultando em um mercado disponível de aproximadamente 14 milhões de pessoas.

Conforme estatísticas do Google Play Store, a taxa de aquisição para novos usuários ( $\%Installs$ ) no período analisado é de 0,23 (mediana), com o primeiro quartil em 0,14 e o terceiro quartil em 0,35. Para usuários retornantes, a taxa de aquisição ( $\%RecoveryInstalls$ ) é de 0,42 (mediana), com primeiro quartil de 0,29 e terceiro quartil de 0,57. A taxa de usuários recorrentes é de 0,7565.

Para estimar o tempo médio em que o usuário permanece ativo no aplicativo, considerando uma taxa de usuários recorrentes de 0,7565 por mês, pode-se aplicar um

conceito da teoria de filas conhecido como “tempo de vida”. Se  $p$  é a probabilidade de um usuário permanecer ativo (taxa de usuários recorrentes), então  $(1 - p)$  é a probabilidade de um usuário desistir ou se tornar inativo no próximo mês (taxa de desistência mensal). O tempo médio,  $T$ , em que um usuário fica ativo pode ser calculado como o inverso da taxa de desistência, assumindo um processo de desistência de Bernoulli. Dado que  $p = 0,7565$ ,  $T = \frac{1}{1-p}$ . Assim,  $T$  é aproximadamente 4.11 meses. Isso sugere que, em média, cada usuário permanece ativo no aplicativo por cerca de 4.11 meses antes de tornar-se inativo.

É cobrada uma taxa de 15% sobre as vendas in-app ( $\%VendorTaxIAP$ ) até o primeiro milhão de dólares [Ajuda do Google Play Console 2023].

Segundo informações do relatório ‘App uninstall report – 2024 edition’ [AppsFlyer 2024], indica-se que a taxa de desinstalação de aplicativos para jogos casuais no Brasil é de 67,4%, em média, 46,67% para os aplicativos entre os 25% mais bem classificados e 2,78% para os aplicativos entre os 10% mais bem classificados. A taxa de churn ( $\%Churn$ ) é o complementar da taxa de desinstalação.

O CPC médio ( $MktCostPerVisit$ ), ou seja, o custo por clique que um anúncio recebe [Amazon Ads 2023], para o setor de Arte e Entretenimento é de 1,55 [Marino 2024]. Os eCPMs ( $ValuePerView$ ), ou seja, o custo efetivo para cada mil impressões de anúncio [Dogtiev 2024], são 1,93 para rewarded ads, 2,31 para interstitials ads e 0,24 para banner ads [Llobet 2024]. Em uma palestra, Moonlit Beshimov, atual chefe do *Google for Games* [Game Developers Conference 2019] indica que o número ideal de ads vistos por dia por usuário ( $ViewsPerUser$ ) é igual a 7.

Um relatório realizado pela empresa Zipdo, sobre compras dentro do app, [Eser 2023] indica que a receita média por compra *in-app* (IAP) ( $IAPAvgValue$ ) é de 8,37, considerando todos os tipos de aplicativos. 10% dos usuários que baixam um aplicativo gratuitamente realizam compras *in-app*, desembolsando, em média, 20,78 dólares por ano.

Com base no gasto médio total por usuário e no gasto por compra *in-app*, pode-se deduzir que o número de compras por usuário é igual a  $= \frac{20.78}{8.37} = 2,4827$ . Considerando que o tempo médio de vida de cada usuário é de 4,11 meses, conclui-se que cada usuário realiza aproximadamente 0,604 compras por mês. Visto que apenas 10% dos usuários realizam compras no aplicativo, a média de vendas IAP por usuário ( $IAPAvgSellsPerUser$ ) é 0,0604.

O *postmortem* do jogo Jelly Splash, usado como guia para esse experimento, [Seufert 2014], exibe um valor inicial de retenção de 92%, declinando para 84% após o lançamento. O coeficiente de viralidade, que representa o número de novas instalações em função das instalações do período anterior, pode ser calculado pela multiplicação das visitas virais ( $ViralVisits$ ) pela taxa de instalação ( $\%Installs$ ), logo a porcentagem de convites por usuário,  $\%ViralVisits$ , é igual a 3,652. Jelly Splash investiu US\$ 10.025 em marketing direto ( $MktInvestment$ ) no Brasil e com período de investimento em marketing,  $MarketingInvestmentPeriod$ , de 1 mês [Seufert 2014].

Para testes do sistema, alguns parâmetros foram estabelecidos com base na experiência dos autores.  $CostPerUser$  foi definido igual a 0,  $FixedCost$  igual a 1.000 dólares,  $MarketingInvestmentValue$  igual a 10.000 dólares.

## 4.2. Implementação e Teste

Nesta seção, são apresentadas as etapas de implementação e teste do modelo dinâmico desenvolvido para a análise do crescimento e da sustentabilidade de empresas baseadas em aplicativos móveis. O objetivo é validar o modelo proposto comparando-o com um modelo de referência, além de realizar uma análise de sensibilidade para avaliar a robustez frente a variações em seus parâmetros.

### 4.2.1. Comparação com o modelo de referência

Como etapa inicial, este estudo compara os resultados possíveis obtidos pelo modelo proposto com os do artigo “Modeling and Predicting the Growth and Death of Membership-based Websites” [Ribeiro 2014], usado como modelo de referência deste trabalho, como especificado na sessão 2.1.2. Para isso, foram estabelecidos dois cenários: no primeiro, mantém-se constante o investimento em marketing enquanto se altera o valor da viralidade; no segundo, a viralidade é mantida constante e o investimento em marketing é variado. Observa-se que o crescimento causado pelo efeito viral é exponencial, como evidenciado nos gráficos da Figura 4. Por outro lado, o efeito causado pelo marketing pago na curva de usuários ativos é convexo, como visto na Figura 5. Isso demonstra que o modelo consegue replicar as curvas esperadas de marketing viral e pago. Ainda em concordância com o modelo de referência, os usuários ativos de empresas sustentáveis seguem uma curva em S, representando um crescimento logístico.

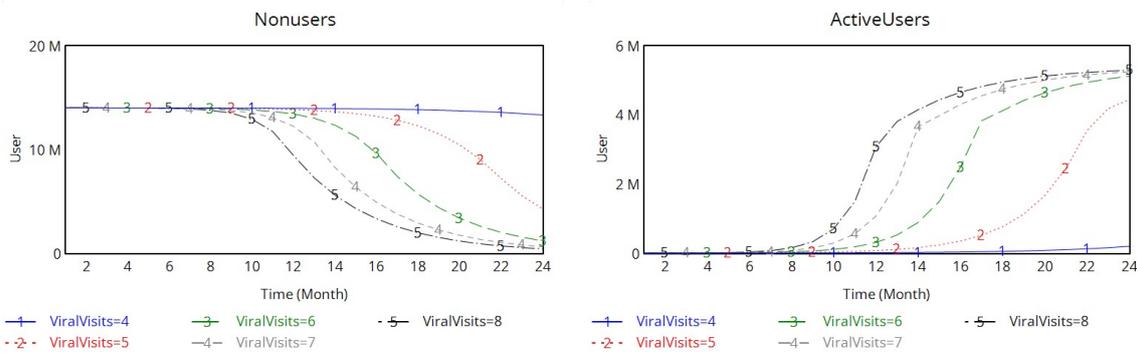


Figura 4. Gráficos de Comparação de Visitas Virais.

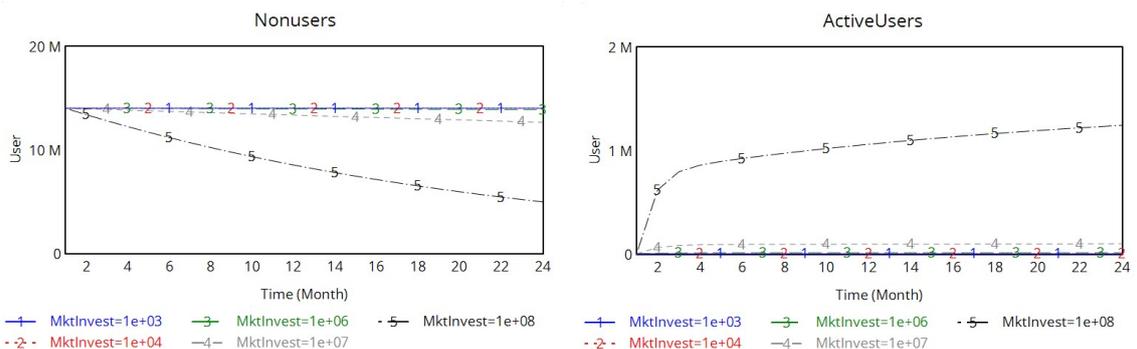


Figura 5. Gráficos de Comparação de investimento em Marketing.

#### 4.2.2. Análise de sensibilidade

Uma das etapas da construção de um sistema dinâmico é o teste do comportamento do modelo e sua sensibilidade a perturbações. Nesta fase, explora-se a robustez do modelo alterando parâmetros e condições iniciais para entender como essas variações afetam os resultados. Experimentos são conduzidos com o modelo para avaliar como o comportamento resultante se modifica sob diferentes configurações de parâmetros. A abordagem utilizada para a análise de sensibilidade consiste em aumentar ou diminuir cada variável em 10% e verificar o impacto dessa mudança no lucro total, *Profit*, que é a variável de interesse do estudo.

O impacto da alteração de cada variável varia conforme a condição inicial. Portanto, foram escolhidas aquelas que representam os quatro quadrantes da *Growth Share Matrix*, também conhecida como matriz BCG. Este framework de gestão de portfólio ajuda as empresas a priorizar seus negócios por meio de uma tabela com dois eixos: *Market Share*, representando a fração de mercado que o produto detém, e *Growth Rate*, indicando a taxa de crescimento do produto [Boston Consulting Group 2024]. Neste framework, a participação no mercado é considerada uma aproximação para a sustentabilidade da empresa. Ademais, Eric Seufert, na conferência do *postmortem* do jogo Jelly Splash, [Seufert 2014] sustenta que a viralidade reflete a qualidade de um aplicativo.

Com base no que foi observado no mercado como valores altos e baixos de cada variável, as seguintes alterações serão feitas para simular cada condição:

- Alto crescimento: aumento do marketing pago, de 10.000 para 50.000, e aumento da taxa de instalação, de 0,23 para 0,35.
- Baixo crescimento: redução do marketing pago, de 10.000 para 1.000, e da taxa de instalação, de 0,23 para 0,14.
- Alta sustentabilidade: redução de churn, de 0,674 para 0,4667, aumento da viralidade, de 3,652 para 5.
- Baixa sustentabilidade: aumento de churn, de 0,674 para 0,86, e redução da viralidade, de 3,652 para 1,5.

Para a análise de sensibilidade, foi avaliado o impacto percentual de alterações na variável-chave sobre o lucro ('Profit') ao final do experimento. O impacto foi medido alterando cada variável em 10% e observando a variação correspondente no lucro. Os produtos foram categorizados em quatro quadrantes, cada um representando um grau de rentabilidade e sustentabilidade.

Para aplicativos categorizados como de alto crescimento e alta sustentabilidade, observou-se que o custo variável por usuário (CostPerUser) exerce a maior influência. Um aumento de 10% nesta variável resultou em uma redução de 12.36% no lucro. A variável AvailableMarket também mostrou sensibilidade significativa, onde um aumento de 10% no tamanho do mercado resultou em um aumento de 9.3% no lucro. Estes resultados sugerem que estratégias focadas na redução de custos por usuário e na expansão para novos mercados podem ser eficazes para aplicativos com alto potencial de crescimento.

Para aplicativos com baixo crescimento e baixa participação no mercado, os custos fixos mostraram a maior sensibilidade, com um aumento de 10% nos custos fixos resultando em uma redução de 9.6% no lucro. Por outro lado, as outras

variáveis apresentaram um impacto muito menor. A segunda maior sensibilidade foi de investimento em marketing (MktInvestmentValue) com uma sensibilidade de apenas 0.37%. Isso sugere que para esses aplicativos, estratégias de redução de custos fixos ou reestruturação operacional podem ser mais adequadas antes de considerar investimentos adicionais em marketing.

Para aplicativos com alto crescimento e baixa participação no mercado, a taxa de desistência dos usuários (%Churn) mostrou uma sensibilidade de 11,5% com um aumento de 10%, enquanto o aumento de 10% em novas instalações (%Installs) resultou paradoxalmente em uma redução de 18% no lucro. Esta sensibilidade negativa implica que, para esses aplicativos, esforços para aumentar as instalações sem uma gestão eficaz do churn podem ser contraproducentes.

Por fim, para aplicativos com baixo crescimento e alta sustentabilidade, a taxa de instalações (%Installs) mostrou uma impressionante sensibilidade de 800%, indicando que um aumento nas instalações pode gerar um aumento substancial no lucro. Da mesma forma, as visitas virais (%ViralVisits) apresentaram uma sensibilidade de 494%, reforçando a ideia de que estratégias voltadas para aquisição de novos clientes podem ser lucrativas para esses aplicativos.

## 5. Conclusão

Este estudo desenvolveu e validou um modelo de System Dynamics para explorar cenários de monetização de aplicativos mobile. Através de uma análise de sensibilidade e de um estudo de caso prático, foi demonstrado como ajustes estratégicos nas variáveis operacionais podem influenciar significativamente o lucro. Evidenciando, assim, a importância de estratégias adaptativas, que consideram as características específicas de cada aplicativo e sua posição no mercado.

Uma das limitações encontradas foi a simplificação da modelagem. O modelo proposto trata uniformemente o impacto do marketing pago e viral entre usuários ativos e inativos; Não considera a possibilidade de segmentação de marketing para excluir usuários que já instalaram o aplicativo; e não considera aplicativos concorrentes.

Para trabalhos futuros, recomenda-se a distinção do impacto de marketing em novos usuários e usuários recuperados. Recomenda-se também considerar a segmentação de marketing e competição com aplicativos semelhantes. Outra possível mudança é segmentar os usuários conforme a satisfação com o aplicativo, bem como categorizar os usuários nas etapas de decisão. Além disso, pode ser incluída a modelagem de aplicativos pagos e por assinatura. Estas melhorias ajudariam a abordar algumas das limitações observadas e a aumentar a robustez do modelo.

Em suma, este estudo destaca o potencial da modelagem de System Dynamics como uma ferramenta estratégica para empresas de aplicativos mobile, proporcionando uma base para decisões informadas e planejamento estratégico.

## Referências

Ajuda do Google Play Console (2023). Taxas de serviço. <https://support.google.com/googleplay/android-developer/answer/112622>. Acesso em: 02 abril 2024.

- Amazon Ads (2023). Cpc (cost per click) explained. <https://advertising.amazon.com/library/guides/cost-per-click>. Acessado em 18 de março de 2024.
- AppsFlyer (2024). App uninstall report - 2024 edition. <https://www.appsflyer.com/resources/reports/app-uninstall-benchmarks/>.
- Boston Consulting Group (2024). What is the growth share matrix? BCG Classics Collection. Acessado em 17 de abril de 2024.
- data.ia (2024). Panorama do setor móvel em 2024. <https://www.data.ai/pt/go/state-of-mobile-2024/>. Acessado em: 21 de fevereiro de 2024.
- Dogtiev, A. (2024). Mobile advertising rates (2024). Acessado em 26 de março de 2024.
- Doyle, C. (2016). *A Dictionary of Marketing*. Oxford quick reference. Oxford University Press.
- Endeavor (2021). O funil de vendas na prática: Um guia para melhorar os resultados do seu negócio com o funil de vendas. <https://endeavor.org.br/vendas/funil-de-vendas-na-pratica/>. Acessado em 13 de março de 2024.
- Eser, A. (2023). Essential in app purchase statistics in 2024. Acessado em 27 de março de 2024.
- Forrester, J. W. (1961). *Industrial dynamics*. MIT press.
- Game Developers Conference (2019). Building successful monetization and growth strategies (GDC 2019). Acessado em 27 de março de 2024.
- Google (2024). Comece agora. Acessado em 26 de março de 2024.
- Google Play (2019). New monetization trends to diversify your game's revenue: Rethinking your game monetization strategy. <https://medium.com/googleplaydev/new-monetization-trends-to-diversify-your-games-revenue-1466bfb3abad>. Acessado em: 02 de março de 2024.
- Instituto Brasileiro de Geografia e Estatística (IBGE) (2023). 161,6 milhões de pessoas com 10 anos ou mais de idade utilizaram a internet no país, em 2022. Acessado em 26 de março de 2024.
- Kotler, P. (2018). *Administração De Marketing*. PEARSON BRASIL.
- Lewis, E. (1908). *Financial advertising*. Harvard pre-1920 social history/business preservation microfilm project. Levey Bros.
- Llobet, M. (2024). The mobile ecpm report: In-app ad monetization worldwide [updated in january 2024]. Acessado em 26 de março de 2024.
- Marino, S. (2024). Google ads benchmarks for your industry [new data]. Acessado em 27 de março de 2024.
- Meadows, D. H., Meadows, D. L., Randers, J., e Behrens III, W. W. (1972). The limits to growth. *New York*, 102:27.
- Randers, J. (1980). *Elements of the System Dynamics Method*. MIT Press/Wright-Allen series in system dynamics. Productivity Press.

- Ribeiro, B. (2014). Modeling and predicting the growth and death of membership-based websites. In *Proceedings of the 23rd International Conference on World Wide Web*, page 653–664. ACM.
- Richardson, G. P. (2011). Reflections on the foundations of system dynamics. *System Dynamics Review*, 27(3):219–243.
- Ross, S., Westerfield, R., Jordan, B., e Lamb, R. (2013). *Fundamentos de Administração Financeira - 9ed.* AMGH Editora.
- Salesforce (2021). Churn rate: o que é e como diminuir? <https://www.salesforce.com/br/blog/churn-rate/>. Acessado em 18 de março de 2024.
- Seufert, E. (2014). Profitably launching jelly splash to #1: A marketing postmortem. <https://www.gdcvault.com/play/1020405/Profitably-Launching-Jelly-Splash-to>.
- SimilarWeb (2024). Traffic share by platform in january 2024. <https://www.similarweb.com/platforms/>. Acessado em: 21 de fevereiro de 2024.
- Vensim (2023). Vensim help.
- Wijaya, B. (2015). The development of hierarchy of effects model in advertising. *INTERNATIONAL RESEARCH JOURNAL OF BUSINESS STUDIES*, 5(1).