

MARCELA SIRCILI MADDARENA

ADAPTAÇÃO DA POLÍTICA DE CRÉDITO EM UMA FINTECH DURANTE A
PANDEMIA DO CORONAVÍRUS

São Paulo

2020

MARCELA SIRCILI MADDARENA

ADAPTAÇÃO DA POLÍTICA DE CRÉDITO EM UMA FINTECH DURANTE A
PANDEMIA DO CORONAVÍRUS

Trabalho de Formatura apresentado à
Escola Politécnica da Universidade de
São Paulo para obtenção de diploma de
Engenheira de Produção

São Paulo

2020

Autorizo a reprodução e divulgação total ou parcial deste trabalho, por qualquer meio convencional ou eletrônico, para fins de estudo e pesquisa, desde que citada a fonte.

Catálogo-na-publicação

Maddarena, Marcela Sircili Maddarena
ADAPTAÇÃO DA POLÍTICA DE CRÉDITO EM UMA FINTECH
DURANTE A PANDEMIA DO CORONAVÍRUS / M. S. M. Maddarena -- São
Paulo, 2020.
104 p.

Trabalho de Formatura - Escola Politécnica da Universidade de
São Paulo. Departamento de Engenharia de Produção.

1. Política de Crédito 2. Bootstrap 3. Escola Politécnica
4. Universidade de São Paulo 5. Fintech I. Universidade de São Paulo. Escola
Politécnica.
Departamento de Engenharia de Produção II. t.

AGRADECIMENTOS

À minha mãe, minha avó, meu padrasto e meu tio que foram fundamentais para a minha formação e que me apoiaram em todos os momentos dessa jornada.

À toda minha família e amigos que tiveram presentes e colaboraram por tornar essa experiência única.

Aos professores que compartilharam seus conhecimentos durante as aulas, principalmente ao meu orientador, Professor Doutor Davi Noboru Nakano, que me ofereceu suporte fundamental para a elaboração deste estudo e por todas as conversas que auxiliaram a atingir o resultado.

À equipe com quem trabalhei durante o estágio, por terem a coragem e a ambição de querer fazer algo diferente.

RESUMO

O presente trabalho objetiva apresentar um plano completo de ações tomadas para adaptar a política de crédito de uma *fintech* durante o período de quarentena devido à pandemia do coronavírus. Com as incertezas que surgiram devido ao cenário, nem todos os modelos e componentes utilizados na política de crédito continuaram tendo outputs condizentes com a realidade. A fim de investigar os componentes que tinham sido afetados e com qual intensidade, foi criada uma *task force* focada nisso. A *task force* fez acompanhamentos em maior detalhe dos modelos utilizados e de alguns componentes da política de crédito. Estudado o efeito que a pandemia teve em cada um dos componentes analisados, foram propostas uma série de alterações na política. Na implementação da nova política construída foi encontrado um erro, pois as estimativas feitas de número de aumentos que seriam dados foram bastante diferentes da realidade. Tal erro levou o time a investigar mais a fundo os experimentos que eram realizados com a política. Foram revistos todos os experimentos que estavam vigentes no momento, seus tamanhos amostrais e, por fim, um estudo sobre o intervalo de confiança das principais métricas variando os tamanhos amostrais. A partir dessa investigação foram propostos o término de alguns experimentos e mudanças do tamanho amostral dos que permaneceriam vigentes e futuros experimentos. Com a aprovação das mudanças proposta, foi possível obter um bom resultado com a nova política de crédito, condizente com as estimativas feitas inicialmente.

Palavras-chave: Política de Crédito. Tamanho Amostral. *Bootstrap*.

ABSTRACT

This work aims to present a complete plan of actions taken to adapt the credit policy of a fintech during the quarantine period due to the coronavirus pandemic. With the uncertainties that arose due to the scenario, not all models and components used in the credit policy continued to have outputs consistent with reality. In order to investigate the components that had been affected and to what extent, a task force focused on this was created. The task force monitored in more detail the models used and some components of the credit policy. After studying the effect that the pandemic had on each of the components analyzed, a series of policy changes were proposed. In the implementation of the new policy built, an error was found, since the estimates made of the number of increases that would be given were quite different from reality. Such an error led the team to further investigate the experiments that were carried out with politics. All the experiments that were in force at the time, their sample sizes were reviewed and, finally, a study on the confidence interval of the main metrics varying the sample sizes. From this investigation, it was proposed to end some experiments and to change the sample size of those that would remain in force and future experiments. With the approval of the proposed changes, it was possible to obtain a good result with the new credit policy, in line with the estimates made initially.

Key Words: Credit Policy. Sample Size. *Bootstrap*.

LISTA DE FIGURAS

Figura 1– Organograma da Credit Tribe	21
Figura 2 – Inferência Estatística	24
Figura 3 – Intervalos de confiança distribuição normal	26
Figura 4 – Intervalos de confiança que indicam informações precisas (marca 1) e imprecisas (marca 2)	26
Figura 5 – Intermediação Financeira	36
Figura 6 – Processo de concessão de crédito com uso de modelos Credit Scoring	45
Figura 7 – Organograma do time de trabalho da Autora	49
Figura 8 – Fluxo de dados para construção das políticas de crédito	52
Figura 9 – Fluxo até o aumento de limite ser dado ao cliente	54

LISTA DE TABELAS

Tabela 1 – Categorias de <i>Machine Learning</i>	32
Tabela 2 – Variáveis e Coeficiente de Ponderação Modelo de Credit Scoring	46
Tabela 3 – Valores esperados de aumento com a política covid	78
Tabela 4 – Experimentos ativos no momento em que o projeto foi realizado	81
Tabela 5 – Valores da métrica delta_ram variando quantidade de reamostragens	84
Tabela 6 - Custo por cliente acumulado por mês para experimentos de controle e increase and block	92
Tabela 7 – Número de Aumentos no primeiro e segundo mês de experimentos increase and block	93
Tabela 8 – Variação das populações em experimento	94
Tabela 9 – Comprometimento da população com experimentos	95

LISTA DE GRÁFICOS

Gráfico 1 – Ponto de Corte e Intervalo de Dúvidas – Credit Scoring	44
Gráfico 2 – Distribuição da população pelo output do modelo e por ecdf	53
Gráfico 3 – Nível de importância dos componentes no modelo de risco	55
Gráfico 4 – Curvas de risco para buckets de 100 bandas	56
Gráfico 5 – Curvas de severidade para buckets de 100 bandas	57
Gráfico 6 – Curvas de gastos para buckets de 100 bandas	58
Gráfico 7 – Curvas de ADB para <i>buckets</i> de 100 bandas	59
Gráfico 8 – Risco por banda de modelo de risco e por profissão	65
Gráfico 9 – Risco por banda de modelo de risco e por renda	66
Gráfico 10 – Porcentagem do limite utilizado no momento que o cliente inicia um atraso de pagamento	67
Gráfico 11 – Variação dos gastos mês a mês nos últimos três anos	68
Gráfico 12 – Variação da taxa de juros por dia nos primeiros meses do ano	69
Gráfico 13 – Monitoramento da delinquência	70
Gráfico 14 – Monitoramento da utilização	70
Gráfico 15 – Aumento de gastos na categoria Supermercado	71
Gráfico 16 – Diminuição de gastos na categoria Lazer	72
Gráfico 17 – AUC do modelo de risco	73
Gráfico 18 – Correlação de Spearman para o modelo de severidade	73
Gráfico 19 – Comparação de AUC dos modelos de risco 1, 2 e 2 covid	75
Gráfico 20 – Alteração do risco com multiplicador	76
Gráfico 21 – Número de transações por semana do ano em 2019 e início de 2020	77
Gráfico 22 – Precisão do Intervalo de Confiança conforme variação dos tamanhos amostrais	86
Gráfico 23 – Precisão do Intervalo de Confiança considerando dois experimentos como um só	88
Gráfico 24 – Precisão do Intervalo de Confiança com novos tamanhos amostrais e antigos	89
Gráfico 25 – Precisão do Intervalo de Confiança com novos tamanhos amostrais	90
Gráfico 26 – Custo por cliente acumulado por mês para experimentos de controle e increase and block	91
Gráfico 27 – Número de aumentos dados por mês	94

LISTA DE ABREVIATURAS E SIGLAS

ADB – *Average Daily Balance*

AUC – *Area Under the Curve*

BA – *Business Analyst* (Analista de Negócios)

BACEN – Banco Central do Brasil

CLP – *Core Limit Policies*

DS – *Data Scientist* (Cientista de Dados)

ETL – *Extract, Transform, Load* (Extrair, Transformar, Armazenar)

FA – *Financial Analyst* (Analista Financeiro)

MLE – *Machine Learning Engineer* (Engenheiro de *Machine Learning*)

NPS – *Net Promoter Score*

OKR – *Objective Key Results*

RAM – *Risk Adjusted-Margin*

RL – *Random Lines*

SCR – Sistema de Informações de Crédito do Banco Central

VPL – Valor Líquido Presente

SUMÁRIO

1. Introdução	15
1.1. A empresa e a definição do problema	15
1.1.1. Cartão de Crédito	16
1.1.2. Conta de Pagamentos	16
1.1.3. Programa de Recompensa	17
1.1.4. Empréstimo Pessoal	17
1.1.5. Conta Pessoa Jurídica (Conta PJ)	18
1.2. Objetivo e escopo	18
1.3. Motivação e importância do trabalho	19
1.4. Papel da autora no desenvolvimento do trabalho	20
1.5. Organização do trabalho	22
2. Revisão Bibliográfica	23
2.1. Estatística	23
2.1.1. Bootstrap	27
2.1.1.1. Intervalo de Confiança Bootstrap-t	28
2.1.1.2. Método Percentil	28
2.1.1.3. Método Bias-Corrected Accelerated (BCa)	29
2.2. Big Data	30
2.3. Machine Learning	31
2.4. Mercado Financeiro	33
2.4.1. Mercado Monetário	34
2.4.2. Mercado de Capitais	34
2.4.3. Mercado Cambial	35
2.4.4. Mercado de Crédito	35
2.5. Processo de Decisão de Crédito Numa Instituição Financeira	36
2.5.1. A Função do Crédito	37
2.5.2. Crédito como Negócio	38
2.5.3. Política de Crédito	38
2.6. A Análise de Crédito	40
2.6.1. Os 5C's do Crédito	41
2.6.2. Credit Scoring	43
3. Diagnóstico da Situação e Desafios na	48
3.1. Análise do time de CLP da empresa	48

3.1.1.	Modo de operação atual	50
3.2.	A política de Crédito	51
3.2.1.	Modelo e Curva de Risco	54
3.2.2.	Modelo e Curva de Severidade	56
3.2.3.	Modelo e Curva de Gastos	58
3.2.4.	Curva de ADB	59
3.2.5.	Bloqueios da Política	59
3.3.	Experimentos	60
3.3.1.	Teste e Controle	62
3.3.2.	Increase And Block	62
3.4.	Problemas e desafios encontrados	63
4.	Desenvolvimento da nova política de crédito Covid	65
4.1.	Monitoramento de componentes da política	65
4.2.	Monitoramento dos modelos	69
4.3.	Formulação da nova política de crédito Covid	74
5.	Problemas verificados na implantação da política de crédito covid	79
5.1.	Análise dos experimentos ativos	80
5.2.	Revisão do tamanho amostral dos experimentos ativos	83
5.3.	Resultados da revisão dos experimentos	93
6.	Conclusão	97
	REFERÊNCIAS BIBLIOGRÁFICAS	99

1. Introdução

Neste capítulo, será apresentada a empresa em que foi realizado o Trabalho de Formatura, bem como as motivações para a realização do projeto e sua relevância. Ao fim, serão apresentados o objetivo do trabalho e a maneira como ele foi estruturado.

1.1. A empresa e a definição do problema

A empresa onde trabalha o Autora do Trabalho de Formatura é uma *fintech* - termo utilizado para designar empresas de tecnologia que visam oferecer serviços financeiros com alto grau de agilidade e baixos custos, o que é possível devido à exploração de meios digitais, processamento de dados em larga escala e tecnologias de ponta. Por motivos de confidencialidade, a empresa será denominada ao longo do documento de "*Fintech X*". O projeto a ser apresentado no documento foi executado durante o período de estágio da Autora na *Fintech X*.

A *fintech* em questão possui uma série de serviços financeiros já oferecidos ao grande público, e conta com mais de 20 milhões de clientes em sua base. Os principais produtos ofertados são: um cartão de crédito, uma conta de pagamentos, um programa de recompensas, uma linha de empréstimo pessoal e uma conta para pessoa jurídica. Ela foi fundada em São Paulo, e possui escritórios localizados nessa cidade, além de escritórios no México, na Argentina e na Colômbia. Tendo uma história relativamente recente, ela é tida como umas das pioneiras e referência na revolução do ecossistema de startups brasileiras.

O cenário de hiper crescimento pelo qual passa a *Fintech X* implica uma série de desafios de escalabilidade. A criação de sistemas, mecanismos e processos que suportem a operação continuada da empresa, de modo que não haja prejuízo em termos de experiência para o cliente, configura-se um dos principais pontos de atenção para a *Fintech X* na atualidade. Este trabalho, embora focado em uma área específica da empresa, visa contribuir para solucionar uma parte deste desafio.

Abaixo, serão descritos com maiores detalhes os produtos oferecidos pela empresa.

1.1.1. *Cartão de Crédito*

O cartão de crédito da *Fintech X* possui dois principais pontos de atratividade: ausência da cobrança de anuidades; e controle de gastos e pagamento de fatura por meio de um aplicativo para smartphones. Além disso, existe tanto o cartão físico quanto a opção de um cartão digital. Ambos os atrativos, embora hoje aparentem ser comuns no mercado brasileiro, eram considerados uma novidade no setor quando o produto foi lançado.

Hoje, o cartão é a principal fonte de receitas da companhia. A *Fintech X*, assim como outras empresas que operam no setor de cartões de crédito, possui ganhos com o produto de três maneiras:

- i) **Taxa de intercâmbio:** um percentual fixo por cada transação realizada com o cartão de crédito;
- ii) **Juros rotativos:** pagamento de juros pelo cliente quando ele atrasa o pagamento de sua fatura;
- iii) **Spread sobre compras feitas no exterior:** taxa fixa para cada operação de compra no exterior, aplicada sobre a cotação do dólar;

Como se pode observar pela natureza do negócio de cartões de crédito, quanto a geração de receita, quanto mais cartões emitidos são utilizados pelos clientes (e suas faturas pagas, ainda que fazendo uso do crédito rotativo), melhor para a companhia. Portanto, grande parte do esforço da *Fintech X* até hoje foi direcionado na aquisição de novos clientes e criação de incentivos para o uso de seu cartão em detrimento dos cartões de seus concorrentes. Os incentivos mais notáveis, e que até hoje são considerados alicerces do negócio da companhia, são um atendimento ao cliente rápido e confiável e um aplicativo com experiência de uso intuitiva.

1.1.2. *Conta de Pagamentos*

A conta de pagamentos da *Fintech X* tem como principal atrativo o fato que o dinheiro nela depositado automaticamente já possui rendimentos atrelados ao CDI (Certificado de Depósito Interbancário) e com ganhos reais acima da poupança. Além disso, não há cobrança de taxas em transferências para outros bancos, e é possível que duas pessoas com contas da

Fintech X realizem transferências entre si a qualquer hora do dia, sem depender do horário comercial.

O produto possui grande importância estratégica no portfólio da empresa, porém não apresenta grande potencial de geração de receita como seu cartão de crédito. Trata-se de um produto de maior abrangência, e como não é aplicada uma análise de crédito quando uma pessoa requisita uma abertura de conta, diferentemente do cartão de crédito, ele possui alcance universal e pode ser considerado um grande potencializador de marca.

1.1.3. Programa de Recompensa

A *Fintech X* lançou seu programa de recompensas com o intuito de estimular compras utilizando o cartão de crédito da empresa. O programa é opcional, e pode ser contratado pagando-se uma mensalidade ou uma anuidade. Com a adesão ao programa, o usuário ganha um "ponto" virtual para cada real gasto em compras, e depois pode utilizar seus pontos para apagar despesas realizadas no cartão ou trocar por pontos em programas de milhagem. O principal diferencial competitivo do produto é a possibilidade de utilização dos pontos para uma variedade grande de compras - desde restaurantes até passagens aéreas - e o fato de os pontos nunca expirarem.

A criação do programa pode ser vista como um movimento estratégico de agregação de valor, um benefício adicional aos usuários do cartão de crédito, porém, assim como a conta de pagamentos, não se configura como um forte driver de receitas da companhia, uma vez que os descontos arrecadados por clientes de alto volume de gastos - os chamados *heavy spenders* - acabam superando o preço da mensalidade do programa.

1.1.4. Empréstimo Pessoal

Trata-se da possibilidade da contratação de um empréstimo que pode ser utilizado para qualquer fim que o cliente desejar. A quantia requisitada é depositada diretamente na conta de pagamentos do cliente, e é possível fazer simulações das taxas de juros e da quantia a ser paga todo mês diretamente do aplicativo da *Fintech X*. Os dois principais pontos de atratividade do programa são o processo de contratação do empréstimo, que dura poucos minutos e pode ser

feito diretamente pelo aplicativo da empresa, e a taxa diferenciada de juros, que se encontra posicionada consideravelmente abaixo da taxa média do mercado.

Embora tenha sido lançado recentemente, o produto gera grande expectativa de geração de receita, uma vez que o recebimento dos juros dos empréstimos contraídos pode alavancar o resultado operacional da empresa de forma significativa. Trata-se de um produto altamente escalável, e que adequa a exposição de risco dos empréstimos de acordo com o perfil de cada cliente, através da utilização de algoritmos de *machine learning*.

1.1.5. Conta Pessoa Jurídica (Conta PJ)

Por fim, o último produto lançado no portfólio da empresa foi a conta para pessoas jurídicas. Esse produto também pode ser visto como uma evolução natural do negócio. Assim como na conta pessoal, a conta para pessoa jurídica não possui nenhuma tarifa e pode ser criada através do aplicativo, sem grandes burocracias. Além disso, é possível gerar extratos OFX (*Open Financial Exchange*) diretamente no aplicativo, o que auxilia a gestão contábil, e, também, existe a possibilidade de gerar um boleto de cobrança, que pode ser enviado diretamente para o cliente.

Atualmente a conta PJ está disponível apenas para clientes da *Fintech X*, seja cartão de crédito ou conta pessoal, que são sócios únicos do seu negócio (tipo societário MEI - microempreendedor individual, EI - empresa individual ou EIRELI - empresa individual de responsabilidade limitada).

1.2. Objetivo e escopo

Atualmente, a política de crédito utilizada pela *Fintech X* é muito conservadora, o que faz os limites de crédito oferecidos não serem altos e como consequência há insatisfação e muitas reclamações. Assim, a otimização da política de crédito é uma das prioridades da *Fintech X*.

O objetivo do Trabalho de Formatura consiste em apresentar o desenvolvimento e implementação de uma política para otimização da política de limite de crédito durante a pandemia do coronavírus. A pandemia gerou uma grande incerteza, em todos os aspectos, e

mudança de comportamento dos consumidores. Assim, as previsões feitas na política de crédito até então vigente, não condiziam com a realidade do momento, pois não levavam em conta as novas incertezas e nem as mudanças de comportamento. Para atender a essa nova realidade sem deixar de dar aumentos de limite, uma nova política e um plano para sua implementação foram elaborados pela Autora e sua equipe (chamada internamente de *squad* de *Core Limit Policies* - CLP).

Neste Trabalho será descrito todo o trabalho realizado por uma *task force* criada exclusivamente para análise dos efeitos da pandemia na política de crédito. Assim, serão detalhados todos os monitoramentos realizados, conclusões tiradas, como foi feita uma adaptação na política para que ela estivesse mais próxima da realidade, sua implementação e problemas encontrados. Durante a implementação da política ocorreu um problema, o qual será tratado com mais detalhes no desenvolvimento deste trabalho.

Sempre que são feitas mudanças na política de crédito, sejam pequenas, como o ajuste da taxa cobrada pela bandeira do cartão sobre cada transação, ou grandes, como no caso de uma nova política, são calculadas estimativas de quantos aumentos de limite serão dados e a soma total desses aumentos. Quando a nova política foi implementada, percebeu-se que um número consideravelmente menor de pessoas havia recebido aumento, quando comparado com a estimativa calculada. Tal problema levou a uma revisão em relação aos experimentos que são realizados com as políticas. A Autora participou ativamente de diversas etapas desse processo, desde a fase de descoberta até a fase de implementação.

1.3. Motivação e importância do trabalho

Segundo dados divulgados pelo Instituto Locomotiva, em agosto de 2019 o Brasil contava com 45 milhões de pessoas desbancarizadas, ou seja, pessoas que não possuem registro nos bancos tradicionais ou que não movimentam sua conta há pelo menos seis meses. Ainda segundo os dados, esse público movimenta cerca de R\$817 bilhões ao ano. Paralelamente, a edição de 2019 da TIC Domicílios, que realiza pesquisas anuais sobre o comportamento do usuário na internet, identificou que 70% dos brasileiros acessam a internet regularmente, realizando encomendas, solicitando serviços ou pesquisando preços. Juntando o resultado das


duas pesquisas é possível identificar um grande potencial de crescimento para os bancos digitais. (COMPUTER WORLD, 2020)

Além do contexto de interesse sobre esse mercado de *fintechs*, com sua crescente atratividade no mercado brasileiro, existe nesse trabalho uma motivação principalmente de caráter pessoal, alinhada ao tema abordado, uma vez que a *fintech* para a qual será feito o estudo é onde a Autora realiza estágio. Tendo em vista as constantes reclamações de seus clientes a respeito do limite de crédito oferecido, o desafio estabelecido fora o de estudar e aplicar técnicas relevantes para resolução do problema enfrentado e, com isso, ajudar a empresa tanto internamente quanto no seu relacionamento com seus clientes.

1.4. Papel da autora no desenvolvimento do trabalho

Desde o início do estágio na *Fintech X* em março de 2020, a Autora, como estagiária de análise de negócios, foi alocada no time de *Core Limit Policies* (CLP). O time de CLP da empresa está localizado na *Credit Tribe*, que reúne todos os *squads* que estão de alguma forma relacionados ao produto cartão de crédito oferecido pela empresa. A *Credit Tribe* também é composta, além de CLP, pelos *squads*: *underserved*, *credit strategy* e *pricing*. Na figura 1 é possível ver o organograma referente à *Credit Tribe*.

Figura 1– Organograma da *Credit Tribe*



Fonte: Elaborado pela Autora

Em linhas gerais, o *squad* de CLP é responsável por tudo o que é relacionado à política de crédito utilizada para definir limite do cartão de crédito de seus clientes. Isto abrange desde a construção da política e dos modelos nelas utilizados, o aprimoramento e o monitoramento da política.

A *Fintech X* utiliza equipes, ou times, para a condução dos seus diversos projetos internos, que são chamadas de “*squads*”. O termo, segundo a metodologia de gestão ágil, é utilizado para designar um time multidisciplinar que possui um objetivo específico dentro de uma organização, e pode ter caráter de curto ou longo prazo (ABRAHAMSSON, 2002). Ele é tradicionalmente utilizado em times de produto, que possuem um entregável tangível e localizado no tempo, o que não é o caso da área de CLP, que está intrinsecamente ligada à própria existência da empresa. Entretanto, seguindo a nomenclatura oficial da empresa, que designa todos os times como *squads*, será adotada esta denominação ao longo do Trabalho.

1.5. Organização do trabalho

O Trabalho de Formatura está organizado em seis capítulos diferentes. O primeiro capítulo consiste na introdução, já apresentada.

O segundo capítulo refere-se à Revisão Bibliográfica, que traz o referencial teórico do que será apresentado ao longo do Trabalho. Serão explorados temas relevantes à decisão de crédito em uma instituição financeira e importância e métodos estatísticos para análise dos modelos utilizados na política.

O terceiro capítulo refere-se à seção de Diagnósticos da empresa. Nele, será descrita a metodologia utilizada para diagnosticar problemas da *Fintech X* e de levantamento de soluções. Em seguida, serão identificados os principais pontos de desenvolvimento da empresa na área de política de limite de crédito, analisando como os processos são realizados atualmente e os problemas e desafios que foram encontrados ao longo do processo.

O quarto capítulo envolve o desenvolvimento do Trabalho, onde serão especificados planos de ação elaborados pela Autora e seu time e como estes planos foram colocados em prática. Trata-se da execução dos planos criados para resolver os problemas identificados no capítulo anterior.

O quinto capítulo irá apresentar os resultados obtidos e uma discussão acerca deles. Durante o período de estágio foi possível não somente planejar e implementar as soluções, como também de discutir com o time responsável pela política de limite de crédito os resultados obtidos.

Por fim, há um capítulo de conclusão, no qual a Autora irá apresentar as considerações finais sobre o Trabalho e o aprendizado obtido.

2. Revisão Bibliográfica

Neste capítulo, será feita a revisão de literatura sobre conceitos e métodos relacionados ao cumprimento do objetivo descrito no capítulo anterior. Os tópicos abordados serão: Estatística, Big Data, *Machine Learning*, Mercado Financeiro, Processo de Decisão de Crédito numa Instituição Financeira e Análise de Crédito.

2.1. Estatística

A estatística fornece métodos para que dados, dos mais diversos tipos referentes ao assunto que a pessoa deseja ter mais informações, possam ser organizados e resumidos a fim de que conclusões em relação a eles sejam mais facilmente obtidas. Uma população representa todos os objetos do estudo, por exemplo, todos os clientes de um banco que possuem cartão de crédito. Quando se tem dados de todos os clientes, isto é, da população, tem-se o que é chamado de censo. Entretanto, nem sempre esses podem ser obtidos: em alguns casos pode ser muito caro obter os dados necessários da população, ou ela não está facilmente acessível para obtenção dos dados. Nesses casos, separa-se amostras da população, na qual todos indivíduos selecionados terão todos os dados necessários levantados para análise (DEVORE, 2006).


A seleção de uma amostra deve ser feita de maneira correta, a fim de garantir que ela seja uma representação da população. Isso significa que ela deve possuir as mesmas características básicas da população, no que diz respeito às variáveis que serão analisadas. Os processos de amostragem podem ser divididos em: amostragem probabilística, onde todos os elementos da população têm probabilidade conhecida e diferente de zero de pertencer à amostra; e amostragem não-probabilística, quando isso não ocorre (COSTA NETO, 2002).

A amostragem probabilística pode ser subdividida em: amostragem casual simples, que equivale a um sorteio lotérico, amostragem sistemática, na qual os elementos são ordenados e há retirada dos elementos da amostra periodicamente; amostragem por conglomerado, onde a população já apresenta uma subdivisão em grupos e escolhe-se um dos grupos para ser a amostra; amostragem estratificada, na qual a população é subdividida em estrato e para cada estrato a variável de interesse varia consideravelmente; e amostragem múltipla, caso em que a amostra é retirada em diversas etapas sucessivas. As amostragens não probabilísticas ocorrem quando nem toda população está acessível, ou quando a ela é formada por um material contínuo, por exemplo análise de água (material líquido), ou ainda no caso da amostragem por voluntários, como no teste de novos medicamentos (COSTA NETO, 2002).

Normalmente, quando se quer fazer uma investigação, apenas algumas características importam. Por exemplo, no caso de clientes de cartão de crédito de um banco, a idade, a profissão, histórico de gastos nos últimos 12 meses etc. Essas características podem ser dados categóricos, como o exemplo da profissão, ou dados numéricos, como os outros dois exemplos citados. Qualquer característica cujo valor pode mudar de um objeto da população para outro, é considerada uma variável. (DEVORE, 2006)

Para descrever e resumir as principais características da amostra de dados coletada, o investigador precisa utilizar métodos da estatística descritiva. Os principais métodos são: construção de gráficos como histogramas e gráficos de dispersão, e o cálculo de medidas numéricas, como média, desvio padrão, variância e coeficientes de correlação. A partir das informações obtidas com os dados da amostra, o investigador tira conclusões a respeito da população inteira. Dessa forma, a amostra é o caminho pelo qual se chega à conclusão para a população. As técnicas de generalização de uma amostra para a população fazem parte da, denominada, inferência estatística. (DEVORE, 2006)

Figura 2 – Inferência Estatística



Fonte: DEVORE, 2006

Na estatística inferencial ou indutiva, como o próprio nome já diz, ocorre um processo de indução, no qual partindo-se do conhecimento de uma parte, a amostra, tira-se conclusões sobre o todo, a população. Esse tipo de processo não é exato, portanto, está sujeito a incertezas, assim, antes de assumir as conclusões da amostra como verdade para toda a população é preciso entender quais são suas incertezas e tentar quantificá-las. A estatística inferencial faz uso de técnicas que visam esclarecer em que pontos pode haver uma incerteza e qual a probabilidade desta incerteza existir. As técnicas mais comumente utilizadas são: estimativa por ponto e estimativa por intervalo. (COSTA NETO, 2002)

Antes de entrar no conceito de cada tipo de estimativa, é importante ter em mente o conceito de estimador e de estimativa. É chamado de estimador a quantidade, calculada através dos dados obtidos com a amostra, que será usada no processo de estimação do parâmetro desejado. Dessa forma, o estimador é uma estatística, uma variável aleatória caracterizada por uma distribuição de probabilidade e seus respectivos parâmetros próprios. E a estimativa é o valor assumido por um estimador. (COSTA NETO, 2002)

Uma estimativa pontual de um parâmetro é um único número que pode ser considerado um valor condizente com o valor real do parâmetro para a população inteira. Para obter uma estimativa pontual é preciso selecionar uma estatística adequada e calcular o valor do parâmetro através dos dados amostrais. A estatística selecionada, que, por exemplo, pode ser a média da população, é chamada de estimador pontual do parâmetro. A estimativa por ponto é geralmente utilizada quando se precisa de um valor aproximado do estimador para ser substituído em uma expressão analítica. (DEVORE, 2006)


A estimativa por ponto, por ser um único número, não fornece por si só informações referentes a precisão e confiabilidade do dado. Suponha que tenha sido calculada a média de uma amostra, com a estimativa pontual a probabilidade dessa média coincidir com a média da população é praticamente nula e não é possível dizer quão próxima a média dessa amostra está da média da população. Devido a esse fato, tem-se a ideia de construir um intervalo em torno da estimativa por ponto, de forma que este intervalo tenha uma probabilidade conhecida de conter o valor real do parâmetro desejado. Este intervalo é chamado de intervalo de confiança. (COSTA NETO, 2002)

Para o cálculo do intervalo de confiança, em geral, assume-se que a distribuição da população é normal, o que é uma suposição razoável. O cálculo do intervalo de confiança varia de acordo com o parâmetro (θ) desejado. Para cada um dos parâmetros mais usuais (média, variância e proporção populacional) existem fórmulas diferentes para fazer o cálculo, e no caso da média a forma varia dependendo se o desvio padrão da população é conhecido ou não. (COSTA NETO, 2002)

Para exemplificar, no caso em que o parâmetro (θ) desejado ser a média, e o desvio padrão (σ) da população for conhecido, o intervalo de confiança é dado pela seguinte fórmula: $IC = \theta \pm z_{\alpha/2} \frac{\sigma}{\sqrt{n}}$, onde θ é o parâmetro desejado, α é o nível de confiança, z é o escore-z que segue uma distribuição normal e é um valor tabelado, σ é o desvio padrão da população e n o tamanho da amostra. A partir da fórmula é calculado o máximo e o mínimo do intervalo de

confiança da média, considerando uma distribuição normal. No caso de distribuições normais, o mínimo do intervalo de confiança equivale ao percentil $\alpha/2\%$ e o máximo ao percentil $(1 - \alpha/2)\%$ (COSTA NETO, 2002).


Figura 3 – Intervalos de confiança distribuição normal



Fonte: DEVORE, 2006

Antes de calcular o intervalo de fato, é preciso determinar o nível de confiança ou grau de confiabilidade (α) do intervalo, os α mais utilizados são 90%, 95% e 99%. Um intervalo com nível de confiança 95%, por exemplo, significa que em 95% das amostras retiradas da população o cálculo do parâmetro desejado fornecerá um intervalo que contenha o valor real deste parâmetro para a população. Quanto maior o nível de confiança, mais preciso o resultado obtido. As informações sobre precisão de uma estimativa de intervalo de confiança são transmitidas através de sua extensão. Quanto maior o α e menor a diferença entre o máximo e o mínimo do intervalo, mais preciso ele é. (DEVORE, 2006)

Figura 4 – Intervalos de confiança que indicam informações precisas (marca 1) e imprecisas (marca 2)



Fonte: DEVORE, 2006

A precisão do intervalo de confiança também está relacionada ao tamanho da amostra, pois considerando uma amostra com tamanho fixo, confiança e precisão tornam-se inversamente proporcionais. Um nível de confiança maior implica que o intervalo de confiança seja maior para abranger mais possibilidades, o que diminui sua precisão. Uma técnica que pode ser utilizada a fim de

obter um intervalo de confiança mais próximo do verídico é o *bootstrap*, que será mais detalhado a seguir. (DEVORE, 2006)

2.1.1. Bootstrap

O *bootstrap* é um método baseado em inteligência computacional que serve para tornar as estimativas estatísticas, como intervalos de confiança, mais precisas. A ideia básica do *bootstrap* é bastante simples, consiste na técnica de reamostragem com repetição da amostra original. Técnicas de reamostragem são bastante utilizadas para facilitar o cálculo de estimadores quando métodos analíticos forem complicados. (EFRON; TIBSHIRANI, 1993)

O método de *bootstrap* possui uma grande vantagem por ser genérico, ou seja, não requer que muitas suposições sobre a amostra inicial sejam feitas. Esse método pode ser aplicado independentemente do tipo de distribuição estatística original do parâmetro estudado, ou mesmo se essa distribuição seja desconhecida. Por se tratar de um método bastante generalista, ele pode ser aplicado para solução de problemas complexos. (EFRON; TIBSHIRANI, 1993)

Como citado anteriormente, é um método baseado em inteligência computacional, pois para repetir um procedimento de análise com muitas réplicas de dados é necessário o auxílio de programas computacionais para que as reamostragens e os cálculos sejam feitos de maneira rápida e eficaz. E, para realizar uma estimativa com o *Bootstrap* é necessário um número grande de iterações. (DAVISON ; HINKLEY, 2008)

Para realizar um teste utilizando o *bootstrap* é preciso coletar uma amostra mestre, que será utilizada na geração das demais amostras. Assim, essa primeira amostra precisa ser coletada de forma planejada, pois caso ela não represente adequadamente a população, o *bootstrap* não levará a resultados confiáveis. A partir da amostra mestre são feitas as reamostragens e é calculado o parâmetro desejado para cada reamostra. (EFRON; TIBSHIRANI, 1993)

O método *Bootstrap* é uma ferramenta útil tanto para o cálculo de desvios padrão quanto para intervalos de confiança mais precisos, em comparação com os métodos tradicionais. O cálculo de desvio padrão de uma distribuição *Bootstrap* para a média, também chamado de erro padrão, é calculado através da fórmula:

$$SE_{bootstrap} = \sqrt{\sum_{b=1}^B \frac{\left(\hat{\theta}^*(b) - \hat{\theta}^*(\sum_{b=1}^B \hat{\theta}^*(b)/B)\right)^2}{B-1}}$$

Onde B é o número de reamostragens realizadas e $\hat{\theta}^*$ é o valor do parâmetro para cada reamostra. (EFRON; TIBSHIRANI, 1993)

Para o cálculo de intervalos de confiança, Efron e Tibshirani (1993) descrevem alguns métodos para cálculo de intervalos de confiança utilizando *bootstrap*, destacando-se os métodos: Método *Bootstrap-t*, Método Percentil e Método *Bias-corrected Accelerated* (BCa). Esses métodos serão apresentados a seguir.

2.1.1.1. Intervalo de Confiança Bootstrap-t

O método *Bootstrap-t* utiliza a tabela *t-Student* e o cálculo do intervalo de confiança é feito utilizando as seguintes fórmulas: $\hat{\theta} - t^{(1-(\alpha/2))} \times SE_{bootstrap}$ para o limite inferior e $\hat{\theta} + t^{\alpha/2} \times SE_{bootstrap}$ para o limite superior, onde $\hat{\theta}$ é o parâmetro, t é encontrado utilizando a tabela t-Student, α é o nível de confiança e $SE_{bootstrap}$ é o desvio padrão bootstrap. Este método é uma generalização do método usual *t-Student*, sendo particularmente aplicável para estatísticas de locação, como a média, a mediana e percentis. O método *Bootstrap-t* não é o mais confiável para o cálculo de outras estatísticas, como o coeficiente de correlação. (EFRON; TIBSHIRANI, 1993)

2.1.1.2. Método Percentil

O intervalo de confiança pode ser calculado de duas formas diferentes utilizando o método percentil. A primeira forma é, para um nível de confiança α , encontrar o percentil $(1 - \frac{\alpha}{2})100\%$ e o percentil $(\alpha/2)100\%$ da média das reamostras da estatística do parâmetro que se deseja calcular. (EFRON; TIBSHIRANI, 1993)

Por ser uma técnica que calcula o parâmetro desejado para diversas amostras, é possível obter com maior facilidade os percentis para a distribuição. Assim, os intervalos de confiança podem ser facilmente calculados a partir dos percentis. Por exemplo, para o cálculo de um

intervalo de confiança com 95%, basta tomar os valores dos percentis 2,5 e 97,5. (DEVORE, 2006)

A segunda forma de obter o intervalo de confiança pelo método percentil é através das diferenças de valores das estatísticas das reamostras em relação ao valor médio dessa mesma estatística nas reamostras. Para estimar o intervalo de confiança de um parâmetro θ é preciso calcular o valor do parâmetro para todas as reamostras de Bootstrap feitas e a média deste parâmetro θ (MONTGOMERY; RUNGER, 2003).

Dessa forma, para um nível de confiança de 95%, obtém-se o intervalo de confiança utilizando o método percentil da seguinte forma: $[\hat{\theta} - P_{97,5\%} \times d; \hat{\theta} - P_{2,5\%} \times d]$. Onde, $\hat{\theta}$ é o parâmetro, $P_{97,5\%}$ é o percentil 97,5%, $P_{2,5\%}$ é o percentil 2,5% e d é a soma das diferenças calculadas entre cada parâmetro e a média do parâmetro. (MONTGOMERY; RUNGER, 2003).

2.1.1.3. Método Bias-Corrected Accelerated (BCa)

O método de Correção de Vício Acelerado (BCa – *Bias Corrected-Accelerated*) permite encontrar o intervalo de confiança quando houver uma assimetria muito grande na forma como os dados estão distribuídos. Neste método, também são utilizados os percentis para obtenção dos extremos do intervalo, mas não necessariamente são os percentis obtidos como no tópico anterior. Neste caso, os percentis dependem de dois números $\hat{a}$ e $\hat{z}_0$, que são chamados respectivamente de aceleração e corretor de viés e podem ser obtidos através das seguintes fórmulas:

$$\hat{a} = \frac{\sum_{i=1}^B (\hat{\theta}_{(i)} - \hat{\theta}_i)^3}{6 \left\{ \sum_{i=1}^B (\hat{\theta}_{(i)} - \hat{\theta}_i)^2 \right\}^{3/2}} \text{ e } \hat{z}_0 = \Phi^{-1} \left(\frac{\#\{\theta(\hat{b}) < \hat{\theta}\}}{B} \right)$$

Onde, Φ^{-1} é a inversa da função de distribuição normal padrão, B é o número de reamostragens realizadas, $\hat{\theta}_i$ é o valor do parâmetro estudado para cada reamostra e $\hat{\theta}_{(i)}$ é a média do parâmetro de todas as reamostragens. (EFRON; TIBSHIRANI, 1993)

E, o intervalo de confiança é calculado da seguinte maneira: $\left[P_{1-(\alpha/2)}^{\alpha 1}; P_{\alpha/2}^{\alpha 2} \right]$ e a forma para cálculo das constantes está descrita a seguir: $\alpha 1 = \Phi \left(\hat{z}_0 + \frac{\hat{z}_0 + z^{(\alpha/2)}}{1 - \hat{a} (\hat{z}_0 + z^{(\alpha/2)})} \right)$ e $\alpha 2 = \Phi \left(\hat{z}_0 + \frac{\hat{z}_0 + z^{(1-(\alpha/2))}}{1 - \hat{a} (\hat{z}_0 + z^{(1-(\alpha/2))})} \right)$. (EFRON; TIBSHIRANI, 1993)

2.2. Big Data

No mundo de hoje, onde todos estão conectados a todo momento, são geradas milhares de informações. A cada segundo é produzida uma imensidade de dados desestruturados, de diversas origens e categorias, e o número de informações produzidas aumenta exponencialmente. Por exemplo, segundo o site *internet live stats*, a cada segundo são feitos 9207 *tweets*, são postadas 1028 fotos no *instagram* e são feitas 87065 pesquisas no *google*.

Big data é um termo utilizado para conjuntos de dados significativamente grandes com estrutura variada e complexa, que impõe dificuldades para armazenamento, análise e visualização. O processo de pesquisa em grandes quantidades de dados é utilizado para revelar padrões e correlações ocultas, e é chamado de análise de *big data*. Essas informações resultantes podem ajudar empresas ou organizações a obter percepções mais ricas e mais profundas além de proporcionar uma vantagem sobre a concorrência. Por esse motivo, as implementações de *big data* precisam ser analisadas e executadas com a maior precisão possível. (SAGIROGLU; SINANC, 2013)

Hoje, as empresas estão explorando *Big Data* para descobrir fatos que não sabiam antes. Esta se tornou uma tarefa importante depois da crise de 2008, pois ela forçou mudanças profundas na maioria dos negócios, especialmente para aqueles que dependem de consumidores em massa. Usando análises avançadas, as empresas podem estudar big data para entender o estado atual dos negócios e rastrear aspectos ainda em evolução, como comportamento do cliente. (RUSSON, 2011)

Big Data requer que análises de dados mais avançadas sejam feitas e essas análises são caracterizadas por três principais componentes: variedade, velocidade e volume. Variedade diz respeito à origem dos dados, que podem vir de diversas fontes diferentes e de três formas diferentes: dados estruturados, dados com *tags* e já separados em campos específicos; dados semi-estruturados, possuem *tags* mas não estão separados em campos específicos; e dados desestruturados, que não possuem nenhum tipo de categorização. A velocidade é necessária para o processamento de todos os dados e, também, está relacionada à rapidez com que uma enorme quantidade de dados é gerada. E, por fim, o volume está relacionado ao tamanho dos dados, que atualmente são maiores do que *terabytes* e *petabytes* (SAGIROGLU; SINANC, 2013).

2.3. Machine Learning

O aprendizado de máquina (ou *Machine Learning*) é um subcampo da inteligência artificial que pode ser definido, de forma bastante abrangente, como o uso de métodos computacionais para análise de dados, visando melhorar o desempenho ou fazer previsões mais precisas. A partir desses métodos são construídos modelos inteligentes, que passam por uma fase de “treinamento”, ou “aprendizado”, na qual recebem dados existentes para assimilar padrões. Depois da fase de treinamento, o modelo pode ser utilizado para classificar uma outra população ainda não analisada. Na ciência da computação, uma das medidas de qualidade dos algoritmos é a complexidade, tanto em tamanho de código quanto em tempo de processamento, mas, para o aprendizado de máquina, há mais uma medida que deve ser considerada, o tamanho da amostra, ou seja, a quantidade de dados que o sistema possui. (MOHRI, ROSTAMIZADEH e TALWALKAR, 2012).

Normalmente, classificam-se os algoritmos de *machine learning* em três categorias: aprendizado supervisionado, aprendizado sem supervisão e aprendizado por reforço. A principal distinção entre as categorias é a respeito do nível de intervenção humana na rotulação dos dados. Nos algoritmos classificados como de aprendizado supervisionado, o modelo matemático é construído tanto com os dados de entrada quanto com os dados de saída esperados. O principal objetivo desses algoritmos é aprender um padrão para saber a saída, de acordo com a entrada dada. As principais tarefas desses tipos de algoritmos é fazer uma classificação, regressão e estimação. Os algoritmos de *machine learning* mais conhecidos dessa categoria são: máquina de suporte vetorial, Naïves Bayes, modelo oculto de Markov, Redes Bayesianas e Redes Neurais Artificiais. (RUSSEL; NORVIG, 2013)

Na aprendizagem sem supervisão, o sistema não possui o resultado que deve estimar, possui apenas os dados de entrada. O objetivo dessa categoria de algoritmo é explorar os dados e encontrar uma estrutura para saída a partir somente das entradas. As principais tarefas desta categoria de algoritmos é fazer uma clusterização e predição. Os algoritmos mais conhecidos são: K-means, modelo de mistura Gaussiana, modelo de mistura de processo Dirichlet, X-means. (QIU et al, 2016).

Tabela 1 – Categorias de *Machine Learning*

Categoria de ML	Tarefa	Algoritmo de ML
Aprendizado Supervisionado	Classificação Regressão Estimação	Máquina de Suporte Vetorial
		Naïves Bayes
		Modelo Oculto de Markov
		Redes Bayseiana
		Redes Neurais Artificiais
Aprendizado sem Supervisão	Clusterização Predição	K-means
		Modelo de Mistura Gaussiana
		Modelo de Mistura de Processo Dirichlet
		X-means
Aprendizado por Reforço	Tomada de Decisão	<i>Q-learning</i>
		<i>R-learning</i>
		<i>TD-learning</i>
		Aprendizado Sarsa

Fonte: Adaptado de QIU et al, 2016

Na categoria de aprendizagem por reforço, os algoritmos identificam automaticamente o comportamento considerado ideal dentro de uma gama de possibilidades, a fim de maximizar seu desempenho. O sistema deve ser capaz de realizar suas atividades designadas sem orientações, a principal tarefa nessa categoria é a de tomar uma decisão. As principais técnicas de algoritmos de *machine learning* para essa categoria são: *Q-learning*, *R-learning*, *TD-learning* e aprendizado Sarsa (GIRYES; ELAD, 2011).

Quanto à última categoria citada, por ter bastante generalidade, seu campo de atuação acaba sendo estudado, também, por outras disciplinas. Sendo as mais comuns: teoria dos jogos, teoria do controle, pesquisa operacional, teoria da informação, otimização baseada em otimização, sistemas multiagentes e algoritmos genéticos. Por fim, cabe ressaltar que as aplicações de sucesso que mais se destacam na categoria de aprendizado por reforço são os veículos autônomos e os jogos contra um componente humano, quando o próprio computador é seu adversário. (BERTSEKAS, 2012)

2.4. Mercado Financeiro

Um mercado é um grupo de compradores e vendedores de determinado bem ou serviço, onde as demandas são determinadas pelos compradores e as ofertas, pelos vendedores. Os mercados podem assumir diferentes formas, às vezes são altamente organizados, quando compradores e vendedores determinam um certo horário e local para encontrarem-se e há ajuda de um leiloeiro para determinação de preços. E, na maioria dos casos, são menos organizados, quando há vários estabelecimentos ofertando o mesmo produto e o preço é determinado por cada estabelecimento. (MANKIW, 2014)

O mercado financeiro representa uma parcela do mercado na qual ocorre o intercâmbio de ativos financeiros, determinando seus preços, entre agentes superavitários e agentes deficitários. Esse mercado deve proporcionar um ambiente de troca transparente e livre. É um dos setores com maior regulação de suas atividades pelas autoridades públicas. A regulamentação se dá através de um conjunto de leis, recomendações e regulamentos, contratos e procedimentos de fiscalização e acompanhamento. Ao tratarmos do mercado brasileiro, as iniciativas de regulação que mais se destacam são: a criação do Mercado Novo no âmbito da Bolsa de Valores de São Paulo (B3, antiga BM&FBovespa), as práticas de Governança Corporativa, o Código de Proteção ao Consumidor e a Lei de Falências. (ASSAF NETO, 2014)

O Mercado Novo é um segmento da B3 destinado à negociação de ações emitidas por empresas que se comprometem com a adoção dos mais altos níveis das práticas de governança corporativa. A governança corporativa é o sistema que permite aos acionistas e cotistas o controle estratégico de suas empresas e a efetiva monitoração da direção executiva. O objetivo das práticas de governança corporativa é assegurar a todos acionistas equidade e responsabilidade pelos resultados e obediência às leis. Algumas das exigências do Mercado Novo são: emissão de ações unicamente ordinárias; manutenção de, ao menos, 25% das ações em negociação no mercado; e obrigação de divulgação de relatórios financeiros completos (BÚSSOLA DO INVESTIDOR, 2014).

O código de proteção ao consumidor foi promulgado em setembro de 1990, e tem como objetivo assegurar o reconhecimento da vulnerabilidade do consumidor. Assim, os fornecedores passaram a ser, de fato, responsabilizados pelos seus produtos e serviços ofertados. Em relação à importância da Lei de Falências, ela possibilitou às empresas em situações críticas uma negociação mais flexível com seus credores. Além de dar uma

oportunidade para que as empresas se reorganizem, mantendo os empregos e os pagamentos aos credores (PROCON, 2020 e TCJE, 2009).

Esse mercado subdivide-se em quatro: mercado monetário, mercado de capitais, mercado cambial e mercado de créditos, descritos a seguir. (ASSAF NETO, 2014)

2.4.1. Mercado Monetário

O mercado monetário tem como objetivo controlar a liquidez monetária da economia e as taxas de juros fixadas pelas autoridades monetárias. Esse mercado é caracterizado, principalmente, pelo tempo de resgate curto e alta liquidez, ou seja, é um mercado de curto ou curtíssimo prazo. E ainda é responsável pela formação das taxas de juros da economia, taxa Selic e taxa DI. (ASSAF NETO, 2014)

São negociados no mercado monetário papéis emitidos pelo Tesouro Nacional, diversos títulos públicos emitidos pelos Estados e Municípios, os certificados de depósitos interfinanceiros (CDI) e títulos de emissão privada. O mercado monetário é essencial para estabelecer o nível de liquidez da economia através do controle e regulação do fluxo de papel moeda e de moeda escritural. (ASSAF NETO, 2014)

2.4.2. Mercado de Capitais

O mercado de capitais possui um papel econômico muito importante no processo de desenvolvimento econômico, pois ele gera grande parte da munição de recursos permanentes para a economia. Essa geração de recursos permanentes se dá, devido à concorrência entre os investidores, aqueles que poupam, e quem precisa de recursos de longo prazo, que é feito no mercado de capitais. (ASSAF NETO, 2014)

Nesse mercado, as principais operações são financiamentos de médio e longo prazos para capital de giro e capital fixo. Além disso, também é possível fazer financiamentos com prazo indeterminado, como as operações que envolvem emissão e subscrição de ações. (ASSAF NETO, 2014)

2.4.3. Mercado Cambial

No mercado cambial, como o nome já indica, é onde são feitas as operações que envolvem moedas internacionais conversíveis. Esse mercado reúne todos os agentes econômicos que, por algum motivo, precisam realizar transações internacionais. Para que essas operações sejam realizadas, existe a taxa cambial, que indica a relação entre uma moeda e a outra. No Brasil, o câmbio é fiscalizado e regulamentado pelo Banco Central, que tem como objetivo fazer um controle das reservas cambiais da economia e manter o valor da moeda nacional em relação às demais. (ASSAF NETO, 2014)


2.4.4. Mercado de Crédito

O mercado de crédito compreende as operações financeiras de curto e médio prazos dos vários agentes econômicos, seja através da concessão de créditos às pessoas físicas ou através de empréstimos e financiamento às empresas. É comum incluir as operações de financiamento de bens de consumo duráveis praticadas pelas sociedades financeiras no âmbito do mercado de créditos. As operações desse mercado são tipicamente realizadas por bancos comerciais e múltiplos. Estas atividades têm como principal objetivo para os bancos, reforçar o volume de captação de recursos. (ASSAF NETO, 2014)

A instituição financeira atua como um intermediário, captando as poupanças para empréstimos e investimentos futuros. Os três principais clientes das instituições financeiras são: pessoas físicas, pessoas jurídicas e órgãos governamentais, sendo o primeiro considerado como principal ofertante e os outros dois como demandantes. Entende-se por ofertante aqueles clientes que poupam mais do que captam, ou seja, depositam mais dinheiro na instituição financeira do que captam na forma de crédito. Já os demandantes, são os que fazem o oposto, captam mais do que poupam. (GITMAN, 2010)

De maneira resumida, a instituição financeira recebe recursos dos poupadores, assumindo a responsabilidade de devolver a quantia acrescida de juros no futuro, e com o capital levantado realizada empréstimos e financiamentos aos tomadores de crédito. Assim como é importante fazer a captação de recursos de forma adequada, é preciso realizar um investimento adequado. Se faz necessária uma análise criteriosa das oportunidades de investimento dos recursos, ou seja, dos tomadores de recursos, garantindo que tenham resultados positivos para a instituição financeira. (ASSAF NETO, 2014)

Figura 5 – Intermediação Financeira



Fonte: ASSAF NETO, 2014

Este tipo de organização precisa estar sempre atualizado em relação a suas informações, principalmente no que diz respeito ao mercado de linhas de crédito oferecidas. Em um mercado em que não há muita estabilidade a preocupação, no processo decisório de crédito, aumenta ainda mais. A instabilidade de um mercado pode ser vista por aumentos ou declínios de vendas súbitos de uma empresa, expansão ou retração de mercados, concorrência acirrada, inflação, elevação de preços, alterações regulamentares na política governamental e inadimplência, todos estes fatores fazem com que o risco de não pagamento aumente, ou seja, que mais pessoas tornem-se inadimplentes.

2.5. Processo de Decisão de Crédito Numa Instituição Financeira

Quando há alguma alteração na disponibilidade de caixa das empresas, as instituições financeiras sentem de maneira imediata, pois isso está diretamente relacionado à capacidade de pagamento dos empréstimos concedidos. Para tentar prevenir problemas, é feito um monitoramento das principais variáveis que influenciam as finanças de uma empresa: faturamento, custos, lucro, fluxo de operações e liquidez dos clientes. Estas variáveis estão ligadas à saúde econômico-financeira das empresas, assim, é imprescindível manter um bom monitoramento delas como forma de apoio às decisões de crédito.

Um executivo do mercado financeiro tem uma pressão maior em relação ao erro, pois lida de uma forma direta com o risco, isto é, a chance de perda financeira. Uma ação equivocada, neste caso, pode provocar prejuízos financeiros à organização, como a decisão ao conceder ou negar crédito a algum cliente, que está diretamente relacionada a um valor monetário. (GITMAN, 2010)

O processo de decisão e o risco envolvido não depende apenas dos conhecimentos acumulados pelo decisor, o principal fator são as informações a respeito do cliente. Ter as informações do cliente verídicas e de forma atualizada é de extrema importância para o processo decisório da concessão de crédito. Tratando-se de um processo decisório complexo nas instituições financeiras, é preciso fazer uma análise mais aprofundada do assunto. Assim, a seguir será analisado o crédito como negócio, onde tem-se o risco como variável importantíssima na decisão, juntamente com outras variáveis do processo.

2.5.1. A Função do Crédito

A palavra crédito vem do latim “*credere*” que significa eu acredito ou confio. A confiança, nesse caso, trata-se de uma atividade bilateral, tanto por parte do adquirente quanto por parte do fornecedor. O fornecedor confia que o adquirente irá cumprir com os prazos para pagamento do crédito concedido dentro do prazo estabelecido. E o adquirente confia que o crédito será depositado como o prometido no acordo de concessão.

O crédito corresponde a uma troca de bens presentes por bens futuros, ou seja, a empresa concede um limite de crédito para o seu cliente por meio de uma promessa de pagamento expresso. Por meio do crédito, o cliente passa a ter um poder de compra maior e, além disso, o crédito serve para criar oportunidades de novos negócios. (CAOINETTE; ALTMAN; NARAYANA; 2000)

Devido às inúmeras facilidades que o crédito pode introduzir na dinâmica do processo econômico, ele tem um importante papel social. Dentre esses papéis destacam-se: oportunidade de empresas expandirem e estímulo ao consumo dos indivíduos (CAOINETTE; ALTMAN; NARAYANA; 2000).

Para as instituições financeiras, as operações de crédito constituem seu principal negócio e consiste em analisar a capacidade de pagamento do cliente que está solicitando o crédito, visando assegurar sua reputação e solidez financeira. (SILVA, 2000)

2.5.2. Crédito como Negócio

Para as instituições financeiras o crédito é visto como seu principal produto na forma de empréstimos ou cartão de crédito. E, como dito anteriormente, é preciso ter informações referentes ao cliente para decidir sobre a concessão de crédito. Dessa forma, quanto mais informações cadastradas no seu sistema a instituição financeira tiver, melhor será sua previsão sobre o risco de o cliente não cumprir com suas obrigações. (CASTRO NETO; SÉRGIO, 2009)

Os bancos possuem os seguintes meios para oferecer crédito aos seus clientes: desconto de duplicatas a receber, empréstimos garantidos por notas promissórias ou cheques pré-datados, outras modalidades de financiamento, e cartão de crédito.

2.5.3. Política de Crédito

Na administração de empresas, as políticas são instrumentos que determinam padrões de decisão para resolução de problemas semelhantes, assim, quando um problema se torna recorrente na empresa, indica-se a criação de uma política.

As políticas de crédito são caracterizadas pelas atividades de concessão de prazo para pagamento das transações comerciais. Nela definem-se a seleção de clientes que receberão o crédito, os limites de créditos, os prazos para pagar e os riscos operacionais. (SILVA, 2000)

Segundo Schrickel (2000), uma “política de crédito deve ser lúcida, flexível e pragmática, ou seja, realista em relação ao mercado, mutável ao longo do tempo, e auxiliadora da concretização dos negócios”.

No que se refere às normas legais, um dos principais parâmetros a ser observado, no Brasil, é aquele traçado pela Resolução nº 4193 (2013) do Banco Central do Brasil. A resolução estabelece a necessidade mínima de um patrimônio líquido ajustado de 8% em relação aos ativos ponderados pelo risco. Tal determinação, dependendo da estrutura de capital de cada instituição, poderá implicar na retração do oferecimento de empréstimos por parte dos bancos, ou mesmo redirecionamento de seus investimentos.

Para que a concessão de crédito tenha liquidez e seja de qualidade, é preciso ter uma política baseada no equilíbrio entre os objetivos da instituição financeira e as necessidades dos clientes. Ela não deve ser voltada para o risco excessivo, visando somente a lucratividade, e

nem extremamente conservadora, negando crédito à maioria dos solicitantes. (MIURA, DAVI, 2000)

Para SILVA (2000), a política de crédito de uma instituição financeira deve contemplar, entre outros fatores:

- **Definição estratégica do banco** – a política de crédito deve ser construída a partir da decisão estratégica da instituição financeira. No planejamento estratégico deve-se definir qual o segmento de clientes que a instituição deseja focar, os produtos que serão oferecidos e os objetivos de lucratividade a serem alcançados pela instituição.
- **Forma de decisão e delegação de poderes** – a decisão de crédito pode ocorrer de três maneiras em uma instituição financeira: individual, conjunta ou colegiada, sendo que este último também conhecido como comitê de crédito. Vale destacar que quanto maior o poder de decisão individual, maior será a agilidade para concessão de crédito, entretanto, isto impacta em um menor controle sobre a qualidade das operações.
- **Análise de Crédito** – definir qual tipo e com qual abrangência será feita a análise de crédito é um dos principais pontos nas operações dessa natureza. Em alguns casos, uma instituição financeira copia a forma de análise utilizada por outra instituição, o que nem sempre é adequado, visto que o perfil dos clientes pode ser diferente. O ideal é ter modelos de análise diferenciados de acordo com perfil, porte e região que o cliente se encontra. A análise de crédito será melhor detalhada mais à frente neste Trabalho.
- **Limites de Crédito** – a definição do limite de crédito que será concedido vai além da abrangência de uma simples análise de crédito, deve-se fixar limites para os diferentes produtos em diferentes prazos. Tais definições devem levar em conta a qualidade do cliente e as garantias a ele associadas. De maneira geral, as instituições financeiras segmentam os limites por cliente em três formas de operação: o financiamento padrão; operações rotativas e operações com derivativos.
- **Normais legais** – em função das instituições utilizarem recursos financeiros captados de terceiros nas suas operações de financiamento existe a necessidade de fiscalização e normatização das operações por parte dos reguladores. Como dito anteriormente, no Brasil o responsável por essas normas é o Banco Central do Brasil

(BACEN) e tem as normas descritas nas resoluções. É de extrema importância que a política de crédito esteja bem alinhada com as normas vigentes.

A política de crédito nas instituições financeiras não representa somente a avaliação dos clientes e aprovação dos limites, deve conter também as regras de precificação em função das avaliações, formas de gestão do risco durante a operação e instrumentos de recuperação das dívidas em atraso.

2.6. A Análise de Crédito

Ao tomar a decisão de conceder crédito, é necessário que seja feita uma análise mais aprofundada do solicitante para ter embasamento na concessão ou não do crédito. A análise de crédito compreende uma série de técnicas para avaliar a capacidade de pagamento do cliente, sendo as três mais comumente usadas: análise subjetiva, análise financeira e análise estatística. (CASTRO NETO; SÉRGIO, 2012)

A função da análise de crédito consiste em avaliar a capacidade de pagamento do solicitante, visando sempre assegurar a reputação e solidez da instituição que está concedendo o crédito. A solidez da instituição é importante, pois ela precisa ter condições de garantir a seus acionistas o retorno esperado, garantindo que seja um retorno maximizado. (SILVA, 2003).

O processo de análise de crédito é vital para a segurança e sustentabilidade das instituições financeiras. Assim, esse processo decisório é a fase mais importante para se conceder crédito de forma adequada. Segundo BLATT (1999), há algumas informações que são indispensáveis nesse processo de análise, sendo elas:

- Cadastro de pessoa física ou jurídica dependendo de quem é o solicitante de crédito;
- Apontamentos cadastrais;
- Sistema de controle operacional;
- Fluxo de caixa e/ou conta corrente;
- Balanços e balancetes;
- Em casos de operações pré-aprovadas, o escore de crédito;
- Ficha de abertura de conta corrente;
- Em casos de pessoas jurídicas, também é preciso verificar a saúde financeira do setor de atuação;

Segundo CAOUETTE (1999), existe uma sequência de passos que deve ser seguida para realização da análise de crédito:

- i) Estabelecimento de interesse mútuo entre as partes, fornecedor e solicitante de crédito
- ii) Análise financeira do solicitante, seja uma pessoa física ou pessoa jurídica
- iii) Análise financeira do setor no qual o solicitante atua
- iv) Análise da administração executiva e estratégia operacional. Esta análise refere-se à avaliação das perspectivas de longo prazo do solicitante.

Em suma, a análise de crédito contempla a avaliação ambiental, a avaliação de desempenho do solicitante e a avaliação das diretrizes estratégicas observadas.

Um dos componentes mais importantes na análise de crédito é o risco que o solicitante possui. O risco, em seu sentido fundamental, é definido como a probabilidade de haver um prejuízo financeiro. No caso da análise de crédito, o risco é o mesmo que a incerteza que se tem sobre o retorno de uma concessão feita. Quanto mais certo for o retorno do crédito concedido, menor o risco. (GITMAN, 2010)

O risco pode ser classificado em quatro grupos: risco do cliente, risco da concessão do crédito, risco da concentração e risco da administração de crédito. O risco está na probabilidade de que algo esperado aconteça ou que algo indesejado aconteça. Por exemplo, uma concordata, ou seja, é definido como uma possibilidade de que aquele que concedeu o crédito não receba o valor esperado do devedor nos prazos e condições definidas. (BLATT, 1999).

A seguir serão detalhados dois métodos de análise de crédito bastante utilizados: os 5C's do crédito e o *Credit Scoring*.

2.6.1. Os 5C's do Crédito

Os 5C's do crédito consistem em uma metodologia de análise de crédito bastante difundida, na qual é feita análise de cinco critérios considerados básicos. Segundo SCHERR (1989), este é o modelo mais tradicional de organização de informações sobre a possibilidade de pagamento de um cliente.

Os critérios são: caráter, capacidade, capital, condições e colateral. Essa metodologia é baseada tanto em fatores subjetivos – caráter e capacidade – quanto em fatores financeiros – capital, condições e colateral. (GITMAN, 2010)

Caráter está relacionado à intenção do cliente em cumprir a promessa de pagamento que foi acordada. Assim, é necessário que as instituições financeiras façam uma pesquisa minuciosa sobre a vida do cliente. Muitas das informações necessárias são preenchidas na ficha cadastral do cliente. Em um processo de análise de crédito, o critério “caráter” é considerado como fator eliminatório, sendo insubstituível no processo. (CASTRO NETO; SÉRGIO, 2009)

Capacidade está relacionada com a capacidade do cliente honrar o crédito pedido. Nesse critério são analisadas tanto a capacidade financeira do cliente quanto sua capacidade gerencial. Para a análise da capacidade financeira há um julgamento baseado nas informações financeiras fornecidas, principalmente nos fluxos de caixa do cliente. Além disso, também são levadas em consideração informações a respeito do ramo de atividade no qual o cliente atua. Para análise da capacidade gerencial, por se tratar de uma análise mais subjetiva, deve-se ter clara a resposta de algumas perguntas sobre o cliente. Algumas das perguntas em questão são:

- Qual é o seu grau de educação?
- Qual é a sua experiência profissional?
- Qual é o seu posicionamento gerencial sobre os negócios? (conservador ou arriscado)
- Possui algum *hobbie* custoso ou que possa ser perigoso?
- Para qual atividade será destinado o crédito, se concedido?

Capital refere-se à situação econômico-financeira do solicitante do crédito. São analisados os demonstrativos contábeis para se ter informações sobre a relação entre a dívida e o patrimônio líquido do solicitante. Este critério é próprio para análise de crédito de pessoas jurídicas e não de pessoas físicas. (CASTRO NETO; SÉRGIO, 2009)

Condições refere-se às condições econômicas gerais e setoriais e quaisquer outras vinculadas a uma transação específica. Nesse critério são feitas análises de fatores externos e macroeconômicos para ajudar no entendimento do momento econômico no qual será desembolsado o crédito e suas possíveis implicações no pagamento da dívida. (CASTRO NETO; SÉRGIO, 2009)

Colateral equivale à garantia, ou seja, o valor dos ativos que cliente dispõe para dar de garantia do crédito. Quanto maiores forem as garantias, maior a chance de a instituição financeira reaver o dinheiro em caso de inadimplência. (GITMAN, 2010)

Vale ressaltar, que a análise apenas desses critérios não é suficiente para decidir sobre a concessão de crédito. (GITMAN, 2010). Segundo SCHERR (1989), este modelo apresenta, do ponto de vista da avaliação para instituição financeira, três desvantagens:


- Não possui consistência temporal nas decisões de crédito. Isto ocorre porque diferentes analistas podem dar pesos diferentes a cada um dos critérios, fazendo com que a decisão varie de acordo com quem realiza a análise.
- Exige que os analistas tenham experiências prévias para terem bons resultados. Como alguns critérios são subjetivos, é preciso que a pessoa que faz a análise já tenha vivenciado casos semelhantes para ter um parâmetro comparativo.
- Não está diretamente alinhado com o objetivo estratégico da instituição. Com a aplicação dessa metodologia não são consideradas perdas pela recusa de bons clientes, ou seja, não está alinhado com o objetivo de maximização de lucros da instituição.

2.6.2. *Credit Scoring*

O *credit scoring* é, também, bastante comum, podendo ser utilizado tanto para concessão de crédito para pessoas físicas quanto para pessoas jurídicas. Quando aplicado a pessoas físicas, utiliza-se informações cadastrais e comportamentais do cliente. Já quando aplicado a empresas, são utilizados índices financeiros como variáveis determinantes. (SAUNDERS, 2000)

Os modelos de *credit scoring* são utilizados para determinar se o solicitante é ou não merecedor de crédito e para determinar o limite máximo que pode ser oferecido. Esses modelos partem da premissa que as características de clientes que irão tornar-se inadimplentes é semelhante às características de clientes que ficaram inadimplentes anteriormente. Os modelos utilizam técnicas estatísticas para determinar um score para o cliente, baseado nos principais fatores que determinam a probabilidade de inadimplência. Apesar de usar técnicas estatísticas, isso não assegura que bons pagadores sejam recusados e nem que maus pagadores sejam rejeitados, como pode ser visto no gráfico a seguir.

Gráfico 1 – Ponto de Corte e Intervalo de Dúvidas – Credit Scoring




Fonte: SANTOS; FAMA (2007)

Para construção de um modelo de *credit scoring* as instituições financeiras devem seguir os seguintes passos:

- i) Utilizar o banco de dados da empresa para que sejam elaboradas amostras de bons e maus pagadores.
- ii) Aplicação de técnicas estatísticas, como análise *logit* e análise *probit*, para determinar variáveis que ajudam na identificação tanto de bons pagadores quanto de maus pagadores.
- iii) Determinação de pesos para as variáveis encontradas anteriormente, de acordo com o seu grau de importância na classificação das pessoas.
- iv) Definição de uma equação para o cálculo do *score* do cliente.
- v) Definição do limiar de corte de bons e maus pagadores.
- vi) Cálculo do limite de crédito baseado em dados referentes à renda e valor do patrimônio do cliente.
- vii) Definição de limites para os diferentes produtos: cheque especial, cartão de crédito e empréstimos.

Figura 6 – Processo de concessão de crédito com uso de modelos Credit Scoring



Fonte: Chaia (2003)

Como citado anteriormente, para pessoas físicas, que é o foco deste Trabalho, são utilizadas informações cadastrais e comportamentais como variáveis nos modelos de *credit scoring*. Algumas das informações que podem ser utilizadas são apontadas por SECURATO (2002): estado civil, idade, tipo de residência (própria ou alugada), há quanto tempo mora na residência atual, ocupação, tempo no emprego, receita bruta, quantidade de cartões de crédito, contas correntes.

SANTOS e FAMA (2007) construíram uma fórmula para cálculo do escore do cliente a partir das seguintes variáveis: aspectos demográficos, idoneidade, capacidade financeira, colateral, relacionamento bancário, fonte geradora de renda e eventos sistêmicos. Cada valor atribuído a uma das variáveis é multiplicado por um coeficiente de ponderação – grau de importância. A tabela 2, a seguir, apresenta as informações que cada variável contém e seu coeficiente de ponderação.

Tabela 2 – Variáveis e Coeficiente de Ponderação Modelo de Credit Scoring

Variável	Informação	Ponderação Coeficientes
Aspectos Demográficos	Idade	4,02%
	Estado Civil	4,17%
	Residência	4,06%
	Tempo na Residência	4,15%
	Número de Dependentes	4,86%
	Plano de Saúde Familiar	3,97%
	Plano de Seguro Residencial	2,48%
	Plano de Seguro para Veículos	2,77%
	Cargo na Atividade Salarial	3,94%
	Tempo de Atuação na Atividade Assalariada	4,27%
Idoneidade	Caráter - Idoneidade do Cliente Pessoa Física	8,10%
	Caráter - Idoneidade da Fonte Geradora de Renda Assalariada	5,22%
Capacidade Financeira	Renda Mensal Líquida	5,38%
Colateral	Patrimônio (bens móveis e imóveis)	3,89%
Relacionamento Bancário	Tempo de Relacionamento com o seu principal Banco	3,31%
	Patrimônio (aplicações financeiras)	4,13%
	Número de Cartões de Crédito	3,86%
	Índice Médio de Comprometimento de Renda com Dívidas Onerosas	5,84%
Fonte Geradora de Renda	Grau de Rotatividade dos Produtos/Serviços em Época de Recessão	4,61%
	Tempo de Atividade Operacional da Fonte Empregadora	4,01%
	Natureza Contratual (Ltda, S.A., S/C Ltda., etc)	2,11%
Eventos Sistêmicos	Situação Macroeconômica	5,45%
	Comportamento da Taxa de Juros em Créditos Rotativos	5,40%

Fonte: Adaptada de SANTOS; FAMA (2007)

Por serem modelos amplamente utilizados pelas instituições financeiras, Caouette, Altman e Narayanan (2000) destacaram suas principais vantagens e desvantagens. Dentre as vantagens tem-se:

- Facilidade para aplicação e interpretação dos modelos. As metodologias utilizadas para aplicação dos modelos são bastante comuns e bem entendidas, assim como as abordagens usadas para avaliá-los.
- Padronização da análise, diminuindo a subjetividade que análises, como os 5C's, possuem. E, como os modelos são construídos baseados na experiência das instituições financeiras, podem ser aplicados tanto aos clientes já existentes quanto aos novos clientes.

- O processo de análise de concessão de crédito se torna mais rápido e mais eficiente. Com a construção dos modelos, não é preciso que analistas façam as análises individualmente para cada cliente, o processo torna-se escalável e, portanto, mais rápido.
- Possibilidade de automatização da análise de crédito e concessão em massa, visto que interação com gerente deixa de ser necessária.

Quanto às desvantagens dos modelos de *credit scoring*, os autores destacam:

- Apesar de ser baseado em metodologias simples, a construção de um modelo de *credit scoring* pode acarretar custos para a instituição financeira. Os custos podem estar associados à contratação de profissionais capacitados, equipamentos e até à coleta de dados.
- Baixa qualidade e/ou falta de dados. Nem sempre a instituição terá todos os dados necessários de todos seus clientes ou clientes em potencial, o que pode afetar a performance do modelo. E mesmo que tenha todos os dados, é necessário que eles sejam fidedignos à realidade.
- Pode ocorrer superestimação da eficácia dos modelos, principalmente de analistas pouco experientes. E, como citado anteriormente, nem sempre os dados serão confiáveis, então é necessário questionar se o resultado do modelo faz sentido de fato.

Verifica-se que os modelos de *credit scoring* tem um grande potencial de trazer benefícios para as instituições financeiras, se desenvolvidos e utilizados adequadamente. Assim, para terem uma melhor performance, os modelos devem ser revistados e avaliados constantemente, verificando se as variáveis e seus respectivos coeficientes de ponderação ainda fazem sentido.

3. Diagnóstico da Situação e Desafios na *Fintech X*

O objetivo deste capítulo é apresentar um diagnóstico preliminar dos desafios encontrados no *squad* de CLP da *Fintech X*.


3.1. O time de CLP da empresa

O time de CLP está localizado na *Credit Tribe*, como citado na introdução, que é o grupo onde se encontram todos os times que estão de alguma forma ligados ao produto cartão de crédito oferecido pela *Fintech X*. Os times que fazem parte da *Credit Tribe* e seus respectivos papéis são: *underserved*, que é responsável pela política de limite de crédito para clientes com limite inferior a R\$500; *credit strategy*, que é o time responsável por determinar se um cliente está ou não elegível a ter um cartão de crédito da *Fintech X* e se sim, com qual limite inicial; *pricing*, responsável por precificar taxa de juros e negociar com os clientes; e *core limit policies* (CLP), que é responsável pelas políticas de crédito que determina o limite de todos os clientes com limite superior a R\$500.

As principais atividades do time de CLP são: construção e aprimoramento de modelos a serem utilizados nas políticas de crédito e construção, manutenção das políticas de crédito proativa, reativa e temporária, além de experimentos para testar possibilidade de novos produtos relacionados ao limite do cartão de crédito. Na política proativa, a *Fintech X* dá um aumento do limite de crédito sem que o cliente tenha pedido, e é a política que mais dá aumento aos clientes atualmente. Na política reativa, o aumento é dado ao cliente que fez uma solicitação através do aplicativo. Já na política temporária, os aumentos possuem tempo para expirar, ou seja, depois de passado o tempo pré-determinado o limite do cliente volta ao anterior.

O organograma abaixo mostra o time inteiro de CLP e suas subdivisões internas de quando a Autora começou seu estágio na *Fintech X*. Pode-se notar que há uma divisão de funções entre os times de engenharia e os times de análises de dados.

Figura 7 – Organograma do time de trabalho da Autora



Fonte: Elaborado pela Autora

A equipe *Pack 1* está focada na política proativa, e é composta por dois analistas de negócios (BAs), dois cientistas de dados (DS), um Engenheiro de *Machine Learning* (MLE) e um analista financeiro (FA). A equipe *Pack 2*, na qual a Autora foi alocada, está focada nas demais políticas: reativa e de limites temporários; e em outros projetos como uma possível política de diminuição do limite. Ela é composta por quatro analistas de negócios (BAs), um Engenheiro de *Machine Learning* (MLE) e um cientista de dados (DS).

O time de engenharia é composto por nove engenheiros e possui uma subdivisão interna. Uma parte do time está focada na infraestrutura para o produto e outra na infraestrutura para receber dados externos referentes aos clientes da *Fintech X*.

Essa configuração multifuncional é comum na *Fintech X*. É esperado que os analistas de negócios e os analistas de dados tenham uma base de habilidades analíticas bastante forte, e que trabalhem durante a sua carreira em diversas áreas, em uma espécie de rotação de trabalho. O objetivo de suas funções é justamente saber extrair e manipular dados e modelos para tomar decisões bem fundamentadas nas mais diversas áreas de negócio.

3.1.1. Modo de operação atual

Como citado anteriormente, o time trabalha dividido em *packs*, que possuem autonomia para realizar seus projetos. O *pack* 1 trabalha focado em melhorias na política proativa, alguns exemplos de projetos feitos por esse time são: novo modelo de gastos usando *random lines* (RL), onde são dados aumentos de limites aleatórios para os clientes; novo modelo de risco com novos dados vindos de outras fontes; e pequenos ajustes na política, como atualização da taxa cobrada pela bandeira do cartão sobre cada compra realizada.

Já o *Pack* 2, foca nos outros tipos de política: a reativa e a temporária. Alguns exemplos de projetos já feitos são: aumentos temporários em datas especiais como *black friday* ou quando o cliente ativa o aviso viagem; e mudanças na forma como é feita política reativa, por exemplo, atrasar em um mês o aumento calculado pela política proativa, para caso o cliente solicite o aumento ele seja dado de maneira reativa.

No cenário de pandemia, com muitas incertezas que surgiram e mudanças de comportamento dos clientes, foi criada uma equipe temporária, a *task force*, focada em estudar esses efeitos. A *task force* foi composta por um cientista de dados, um engenheiro e três analistas de negócios, sendo uma delas a Autora deste trabalho. As atividades realizadas pela *task force* serão melhor descritas mais à frente.

Na *Fintech X* os times utilizam OKRs (*objective key results*) para definirem seus objetivos, geralmente os OKRs visam um objetivo que possa ser cumprido em três meses, ou objetivos com metas definidas para serem cumpridas nos próximos três e seis meses. E para cada um dos objetivos, existem algumas métricas que foram definidas a fim de que os objetivos possam ser considerados como cumpridos. Com o cenário pandêmico os OKRs tanto da empresa como um todo quanto de cada time foram atualizados, a fim de ficarem focados em objetivos condizentes com a nova realidade. Atualmente, os OKRs e suas métricas do time de CLP são:

1. Resistir à tempestade e vencer o momento da verdade - este objetivo está diretamente ligado ao cenário de pandemia.
 - a. ter alguma política proativa no ar novamente dando aumentos;
 - b. ter pelo menos um milhão de clientes impactados por políticas de resposta à crise;

- c. manter a saúde do time durante a crise;
- 2. Fazer investimentos estratégicos de longo prazo.
 - a. ter no mínimo 3.000 clientes na plataforma de limites, que está sendo desenvolvida, com os fluxos proativo, reativo e emergencial;
 - b. habilitar a coleta de dados de fontes que não *bureaus* de pelo menos 4 fontes novas;
 - c. ter 100% dos modelos e *features* monitorados com *dashboards* acessíveis;
 - d. experimentos do tipo *increase and block* lançados mensalmente e com zero problemas de execução;
 - e. melhorar o VPL (valor presente líquido) esperado para todas as políticas em 15%;
- 3. Maximizar o impacto do cliente.
 - a. aumentar em 1% a quantidade de aumentos reativos dados;
 - b. aumentar a satisfação dos clientes com o limite (NPS - *Net Promoter Score*);
 - c. manter estável a taxa de contato por aumento de limite do cartão de crédito;
 - d. reduzir a taxa de *churn* de clientes devido ao não aumento de limite;


3.2. A política de Crédito

A política de crédito decide se certo cliente receberá ou não um aumento do seu limite do cartão. Para chegar a uma decisão, há um fluxo de transformações de dados que é a mesma para as três principais políticas (proativa, reativa e temporária). A diferença está no final do fluxo, onde há uma otimização do limite, na qual os critérios para otimização variam de acordo com o tipo de política. Em uma primeira etapa, são coletados tanto dados obtidos internamente na *Fintech X*, quanto dados externos, comprados de *bureaus* financeiros.

Os dados internos são provenientes da movimentação da conta dos clientes que também possuem conta na *Fintech X* e das faturas anteriores do cartão de crédito. Quanto aos dados externos, estes são provenientes de diferentes fontes e fornecem dados a respeito do cliente nos diferentes bancos em que ele possua conta ou cartão de crédito. O principal *bureau* de dados no Brasil é o SCR (Sistema de Informações de Crédito do Banco Central) e reúne informações sobre operações de crédito, avais e fianças de pessoas tanto físicas quanto jurídicas no país.

Todos os bancos no Brasil são obrigados, por lei, a enviar mensalmente como está a situação de crédito de cada cliente para o Banco Central.

Figura 8 – Fluxo de dados para construção das políticas de crédito



Fonte: Elaborado pela Autora

A partir dos dados, são construídos e treinados modelos com uso de *machine learning*, que possuem como objetivo fazer uma predição a partir de dados do passado. Os principais modelos na *Fintech X* são: de risco, o de gasto e o de severidade, que serão melhor descritos mais à frente. Os modelos geram uma predição sobre cada cliente, seja a probabilidade de tornar-se inadimplente ou qual será o gasto do cliente num futuro pré-determinado. A população que cada modelo utiliza para ser treinado será mais bem detalhada no tópico específico de cada modelo.


Um ponto relevante a respeito de todos os modelos é que vários deles possuem um período de censura, o que faz com que os modelos sejam treinados com dados muito antigos. Em uma população como a da *Fintech X* que está em constante mudança, seja por expansão geográfica ou canais de aquisições diferentes, isso pode ser um problema, já que a predição pode ficar consideravelmente diferente da realidade em um intervalo de tempo pequeno.

A fim de normalizar e facilitar a classificação de um cliente em relação a outro, é atribuído a cada cliente um escore para cada modelo, tornando possível entender de maneira mais direta qual cliente possui um risco maior do que o outro, por exemplo. Os modelos dão um escore para cliente uma vez por mês, quatro dias após a data de vencimento da fatura anterior. Os modelos e seus respectivos escores serão melhor detalhados mais à frente.

Os modelos dão uma visão de curto prazo, com prazo variando de acordo com cada modelo, sobre cada cliente. Como a *Fintech X* busca ter uma visão mais a longo prazo, são construídas curvas a partir dos *outputs* dos modelos. Normalmente, o *output* do modelo para todos os clientes não está distribuído de maneira uniforme, então é feito um agrupamento de

clientes que possuem comportamento semelhante através da função de distribuição empírica (ecdf - *empirical distribution function*). Essa função agrupa uma mesma quantidade de clientes em cada valor de banda possível.

Gráfico 2 – Distribuição da população pelo output do modelo e por ecdf



Fonte: Elaborado pela Autora


As curvas são feitas para 120 meses, entretanto usam dados reais apenas para os primeiros meses e depois é feita a regressão linear à média. As principais curvas são a de risco, a de severidade, a de gastos e a ADB (*average daily balance*), sendo que essa última não possui um modelo próprio. Com os *outputs*, que são previsões a respeito de cada cliente, obtidos dos modelos e das curvas, são feitas as políticas reativa, proativa e temporária.

Para decisão final sobre o aumento ou não do limite do cliente, são levados em consideração as previsões feitas em relação aos seus gastos, tanto nacional quanto internacional, seu risco de tornar-se inadimplente, as possíveis receitas ou custos que a *Fintech X* terá com esse cliente. No caso das políticas proativa e reativa, para tomar a decisão final sobre aumento do limite, é utilizado o limite que possui Valor Presente Líquido (VPL) otimizado para 12 meses, que será o mais lucrativo, e que ainda seja lucrativo em 99 meses. O critério de decisão de ambas as políticas são os mesmos e, por isso, atualmente a política reativa não dá tantos aumentos aos clientes. Já para a política temporária, a otimização é feita para o VPL em 6 meses e que ainda seja lucrativo em 24 meses. Por não ser uma política que dá aumentos permanentes, ela é menos conservadora que as demais.

São calculados os VPL para limites que variam do limite atual do cliente até o dobro de seu valor ou R\$5.000 a mais do limite, variando de R\$50 em R\$50. O aumento máximo de limite que a *Fintech X* dá em um mês aos seus clientes é o menor valor entre 100% do limite atual ou R\$5.000, com um aumento mínimo de 10% do limite atual. O resultado que a política de crédito retorna é o limite ótimo calculado, depois disso ainda há alguns bloqueios e participação ativa ou não em algum experimento que são levados em conta para decidir se o

cliente realmente receberá o aumento determinado pela política. Os bloqueios e os experimentos serão melhor detalhados após a descrição dos principais modelos e curvas utilizados.

Figura 9 – Fluxo até o aumento de limite ser dado ao cliente



Fonte: Elaborado pela Autora


Após os bloqueios e conferência sobre participação em experimentos, para que o aumento de fato seja dado aos clientes é preciso que ele chegue ao sistema de serviço da *Fintech X*. Nele os aumentos são de fato concedidos, e para decisão sair da base de dados e chegar até o sistema ocorre um processo conhecido como ETL (*Extract, Transform and Load*). Neste processo, os dados são extraídos dos sistemas de armazenamento, transformados conforme as regras do negócio e, por fim, carregados no sistema pré-determinado, que no caso é o sistema de serviços. O processo de ETL pode ser bastante complexo e podem ocorrer problemas de execução que afetem significativamente os negócios, portanto é sempre um ponto de atenção para o time de CLP para garantir que os aumentos estão sendo dados corretamente.

3.2.1. Modelo e Curva de Risco

O modelo de risco prediz se o cliente irá tornar-se inadimplente nos próximos seis meses. Na *Fintech X* é considerado que o cliente está inadimplente quando o atraso do pagamento de alguma fatura, mesmo que apenas de um valor parcial, chega a 60 dias. Para a construção do modelo de risco são considerados em torno de 250 fatores diferentes, provenientes tanto das fontes de dados externas quanto internas. Dentre os principais fatores, pode-se citar: utilização do limite, há quanto tempo possui o cartão da *Fintech X*, escores de bureaus de dados, idade do cliente, soma de gastos em cada categoria (lazer, educação, casa etc.) e dia de fechamento da fatura. No gráfico abaixo é possível ver o ranqueamento de importância que cada componente tem no modelo. Para fazer o ranqueamento de importância dos componentes foi utilizada a metodologia SHAP (*SHapley Additive exPlanations*), que é

uma abordagem de código aberto que busca explicar quão bem cada componente segrega a classificação de risco. Quanto maior o valor de SHAP, maior a segregação que o componente faz e, portanto, maior sua importância para o modelo de risco.

Gráfico 3 – Nível de importância dos componentes no modelo de risco




Fonte: Elaborado pela Autora

Este modelo é treinado utilizando dados de um período de 18 meses de 50% da população. O valor que o modelo retorna é um número entre zero e um, e o valor indica a chance de o cliente tornar-se inadimplente nos próximos seis meses. Por exemplo, um output de 0,08 significa que o cliente tem 8% de ficar inadimplente nos próximos seis meses.

Para a distribuição ecdf, são construídas bandas de 0 a 1000, sendo que quanto menor a banda, maior o risco. Assim, um cliente com banda 100 apresenta um risco alto de tornar-se inadimplente, enquanto um cliente com banda 800 apresenta um risco bem baixo. Para a construção da curva de risco, é feito agrupamento em *buckets* de 20 bandas cada, e então, é traçada uma curva para cada uma delas.

A curva de risco mostra a probabilidade de inadimplência a cada mês e é construída para 120 meses, como dito anteriormente, neste caso específico, os 18 primeiros meses são construídos utilizando dados antigos de clientes e nos demais meses, é feita uma regressão linear à média. A população usada no treino da curva equivale a 30% do total, sendo que esses 30% não participaram do treinamento do modelo. A curva usa como dados de entrada os outputs do modelo de risco e faz algumas transformações nos dados para que seja construída uma curva mais monótona. Para isso, na construção da curva são aplicadas uma função monótona e uma função suavizadora (*smoothing*), a fim de deixar a curva mais regular. Além disso, no caso da curva de risco ainda é feito um ajuste de 7% em relação ao seu cálculo, ou seja, os valores são multiplicados por 1,07 para construir a curva.

Gráfico 4 – Curvas de risco para *buckets* de 100 bandas



Fonte: Elaborado pela Autora

3.2.2. Modelo e Curva de Severidade


O modelo de severidade prediz quanto do limite, em porcentagem, o cliente deixará de pagar após 180 dias de atraso, caso fique atrasado. O *output* do modelo é um número que varia entre 0 e 1, representando a porcentagem do limite que o cliente deixará de pagar. Por exemplo, no caso do *output* do cliente ser 0,5, isso significa que, após 180 dias de atraso, ele não terá

pago 50% do limite que possui e, como consequência, a *Fintech X* considerará como perda essa porcentagem do limite. O quanto um cliente deixa de pagar após 180 dias é considerado como perda pela *Fintech X*, ou seja, é a quantia de dinheiro que não irá reaver.

Este modelo é treinado com dados de um período de 12 meses e de 70% da população. Essa grande porcentagem de população que é utilizada no treinamento do modelo se dá pois ele utiliza apenas pessoas que de fato ficaram atrasadas por mais de 180 dias. Assim como no modelo de risco, também são construídas bandas de ecdf que variam de 0 a 1000. Entretanto, nesse caso, quanto menor a banda menor a porcentagem do limite que a predição diz que o cliente deixará de pagar, ou seja, mais seguro o cliente.

A curva de severidade mostra a predição de qual porcentagem do limite irá tornar-se perda, para cada mês caso o cliente atrase o pagamento, e é construída para 120 meses, como dito anteriormente. No caso dessa curva em específico, os 12 primeiros meses foram construídos utilizando dados antigos de clientes e, para os demais meses, é feita uma regressão linear à média. A população utilizada no treino de curva é de 20% do total, sendo que esses não fazem parte da população de treino do modelo de severidade. A curva usa como dados de entrada os outputs do modelo de severidade e, assim como na curva de risco, são aplicadas funções monótonas e suavizadoras (*smoothing*) na curva.

Gráfico 5 – Curvas de severidade para *buckets* de 100 bandas




Fonte: Elaborada pela Autora

3.2.3. Modelo e Curva de Gastos

O modelo de gastos é um modelo de regressão que prediz a soma de gastos de cada cliente nos próximos três meses em relação à soma do limite disponível que este cliente tem para o mesmo período. O output modelo é o valor previsto para o gasto, sendo maior ou igual a zero. O modelo divide os clientes por comportamento de gastos, é usado como base para construção da curva de risco e, também, é usado para prever os gastos caso o cliente receba um aumento de limite. Inclusive, essa previsão de gastos com um aumento de limite é utilizada para o cálculo do VPL tanto no curto prazo (12 meses) quanto no longo prazo (99 meses). Diferentemente dos modelos citados até então, este modelo possui um importante papel nas projeções de receita na área de cartão de crédito da *Fintech X*.

A curva de gastos é construída a partir dos *outputs* do modelo e faz a previsão de qual será o gasto do cliente nos próximos três meses de acordo com a soma do limite disponível que ele possui. Assim como as demais curvas, essa curva também utiliza bandas de 0 a 1000 construídas a partir dos outputs do modelo e, quanto maior a banda, mais propenso a gastar o cliente é. Além disso, essa curva também passa pelas mesmas transformações que as demais, com uma função monótona e de suavização (*smoothing*).

Gráfico 6 – Curvas de gastos para buckets de 100 bandas




Fonte: Elaborado pela Autora

3.2.4. Curva de ADB

A curva de ADB (*average daily balance*) não possui um modelo próprio, mas utiliza os dados do modelo de risco para ser calculada. A curva retrata a razão entre ADB e PV (*purchase volume*), onde PV representa o quanto o cliente gastou naquela fatura. A curva de ADB é utilizada para calcular a receita de juros. Assim como as demais curvas, esta também é construída para 120 meses e utiliza dados reais para a construção dos 18 primeiros meses e para os demais é feita uma regressão linear à média.

Há algumas suposições que são levadas em consideração na construção da curva: ADB/PV é constante para diferentes PVs, não é levado em conta um efeito de segunda ordem; é considerada uma convergência no longo prazo; a receita por juros é considerada como zero para as duas primeiras faturas de um cliente; a curva de ADB é construída considerando apenas clientes que não estavam bloqueados na score date utilizada e utiliza 30% da população para ser treinada.

Gráfico 7 – Curvas de ADB para *buckets* de 100 bandas



Fonte: Elaborado pela Autora

3.2.5. Bloqueios da Política

Após o cálculo do limite ótimo, ou seja, com VPL ótimo em 12 meses e ainda positivo em 99 meses, ainda ocorre a fase de bloqueios. Nela, existem alguns fatores que são examinados

para decidir se aquele limite ótimo calculado pode ser de fato oferecido ao cliente. Os fatores que bloqueiam o aumento de limite são:

- Último aumento muito recente, há menos de 40 dias.
- Escore de risco menor do que a banda 200 da distribuição ecdf.
- Negativado em algum *bureau* de dados.
- Com empréstimo ativo.
- A razão entre as dívidas em aberto do cliente e sua renda tem que ser no máximo 100%, sendo que as dívidas podem ser tanto na *Fintech X* quanto em outras instituições às quais tem-se acesso aos dados através dos *bureaus*.
- Margem de utilização, quanto o gasto médio do cliente irá aumentar com o aumento do limite, tem que ser maior ou igual a 5%.
- Com pagamento da fatura em atraso, tanto na *Fintech X* quanto segundo dados de *bureaus*.
- Com pagamento de alguma fatura anterior parcelada e sem estar totalmente quitada.
- Cliente há menos de dois meses, nesse caso em específico, há ainda uma verificação do escore de risco, que caso seja muito baixo o período aumenta para três ou quatro meses.
- Não possui cartão ativo.
- Possui *tags* específicas, como, por exemplo, de fraude.
- Com pagamento atrasado em alguma outra instituição, isso é verificado a partir dos dados obtidos com os *bureaus*.

3.3. Experimentos

Em CLP constantemente são feitos experimentos, com uma parcela da população, para validar e mensurar o impacto de hipóteses criadas, seja a respeito de modelos, de curvas, da política como um todo ou de uma potencial mudança em telas do aplicativo relacionadas com o limite do cartão do cartão. Existem alguns experimentos que ocorrem pontualmente e outros que são recorrentes.

Os experimentos pontuais têm como objetivo validar se uma hipótese criada tem o impacto esperado. Alguns exemplos de experimentos pontuais que já foram feitos na *Fintech X* são: experimento de aumento manual pelos atendentes do chat, visando ver se havia algum ponto cego na política que os atendentes conseguiriam perceber; aumentos de limite temporário

para determinados grupos, por exemplo pessoas com aviso viagem ativado, ou em datas especiais, como *black friday* e dia das crianças, entre outros. Todos esses experimentos são feitos usando um grupo controle, que fica sem receber aumentos.

Os experimentos recorrentes, que tem como objetivo monitorar o efeito dos aumentos de limite, principalmente a mudança no delta VPL esperado de cada cliente, e ajudar a entender possíveis pontos de melhoria. Os dois principais experimentos recorrentes são: teste e controle e *increase and block*, que serão melhor descritos a seguir.

Um ponto importante é que todos os experimentos que deixam de dar aumentos para os clientes geram um custo para a *Fintech X*. Esse custo ocorre porque o aumento de receita da *Fintech X* na área de cartão de crédito está diretamente relacionado ao gasto que os clientes fazem. Assim, ao deixar de dar um aumento calculado pela política, impedimos que o cliente possa gastar esse limite a mais e, por consequência, o VPL da *Fintech* não aumenta.

Para que os clientes fiquem de fato ativos nos experimentos, eles devem atender algumas condições. Essas condições são pré-determinadas no momento em que os experimentos são criados. As condições mais comuns são: tempo desde que a conta foi criada, ter estado ativo em algum experimento recente, ter recebido aumento recentemente e escore de risco.

A escolha dos clientes que participam de determinado experimento é feita utilizando um número arbitrário que divide toda população disponível, ou seja, que não está em experimentos, de forma ortogonal. Cada número arbitrário divide toda a população disponível em 1000 *buckets*, cada um contendo a mesma quantidade de pessoas. Sabendo a quantidade de pessoas que se deseja ter no ativa no experimento, é preciso rodar uma vez o experimento com um intervalo arbitrário de *buckets*, e assim descobrir quantos clientes ativos existem por *bucket* e, por fim, calcular proporcionalmente o número de *buckets* necessários para obter a população desejada no experimento.

Nem todos os clientes que estão nos *buckets* selecionados serão considerados como ativos no experimento, estes são considerados divergentes. Esses não entram na população disponível para outros experimentos, ou seja, mesmo sem estarem participando ativamente de um experimento são considerados como população não disponível. Os clientes divergentes ficam sujeitos à política de crédito padrão. Além das definições descritas acima, das condições que os clientes devem atender para ficarem ativos nos experimentos, do número aleatório que distribui a população e dos *buckets* que serão utilizados, também precisam ser definidos: a data

de início do experimento, a duração do experimento e a qual política os clientes do experimento vão estar sujeitos.

3.3.1. *Teste e Controle*

Nos experimentos chamados de teste, todos os clientes que estão ativos podem receber aumentos durante todo o período do teste, como se estivessem na política padrão. Normalmente o nome desses experimentos está associado a uma versão da política, por exemplo, quando houve o lançamento da versão três da política, foram lançados os experimentos *test_v3* e *control_v3*. Apesar do nome do experimento estar relacionado a uma versão da política, os clientes que estão ativos no experimento não ficam sujeitos apenas a aumentos da versão da política que dá nome ao experimento, mas sim à política padrão, mesmo que seja lançada uma nova versão da política. O experimento existe para garantir que uma parcela da população não entre em outros experimentos e que não sejam dados aumentos temporários ou reativos, para que possam ser analisados os aumentos dados pela política proativa de fato.

No controle, desde o início até o final do experimento todos os clientes ativos nesses experimentos ficam bloqueados de receber qualquer aumento de limite, independentemente de ser por política proativa, reativa ou algum limite temporário. Este tipo de experimento é o que gera maior custo para a *Fintech X*, visto que nenhum aumento é dado para esses clientes.

3.3.2. *Increase And Block*

Nesses experimentos todos os clientes ficam elegíveis a receber aumento no primeiro mês, os que recebem o aumento ficam bloqueados, na política de controle, durante o resto do período e os demais são liberados para política padrão. A política a qual os clientes ficam elegíveis no primeiro mês, em geral, é a política padrão, mas existem algumas exceções em que é utilizada uma outra política. Lembrando que existem algumas condições que o cliente precisa cumprir para ficar ativo no experimento, ou seja, estar dentre os clientes que podem receber aumento e ficarem bloqueados. Este tipo de experimento implica em um custo para *Fintech X*, pois durante o tempo de bloqueio o cliente deixa de receber aumentos.

Quando um experimento de *increase and block* é lançado junto com um teste, não há necessidade de fazer um controle específico, pois o controle do teste pode ser utilizado.

Entretanto, nos casos em que isso não ocorre, é preciso lançar um outro experimento que é chamado de *control and release*. Nesse experimento, só ficam bloqueados durante todo o período os clientes que estavam elegíveis a receber um aumento no primeiro mês e os demais são liberados para a política padrão. Para ver quais clientes estavam elegíveis, são usados os arquivos das políticas, que são gerados diariamente e armazenam a decisão da política naquele dia.

O tamanho da população alocada neste tipo de experimento é calculado da seguinte forma: população que queremos que receba aumento no primeiro mês / taxa de aprovação da política utilizada. Assim, se a taxa de aprovação da política é em média 20% e queremos ter cem mil clientes no experimento para analisarmos, é preciso reservar 500.000 pessoas que fiquem ativas no experimento. O que, devido às condições que são impostas, pode fazer com que uma quantidade muito maior de clientes seja reservada para o experimento.

3.4. Os problemas e desafios encontrados com a pandemia

Com o início da pandemia do novo coronavírus no Brasil e, consequentemente, quarentena ou até *lockdown* em algumas cidades, surgiu um cenário de grandes incertezas, muitos estabelecimentos fechando, mercado de eventos muito afetado, pessoas perdendo emprego. Como consequência disso, a política de crédito até então utilizada deixou de representar a realidade brasileira e, acabou, por tornar-se muito arriscada para a *Fintech X*.

Assim, a decisão tomada inicialmente foi a de desativar a política, ou seja, nenhum cliente iria receber aumento de seu limite do cartão de crédito, e com a política desligada, entender quais os principais efeitos que a crise teve no comportamento dos clientes e como adaptar-se ao novo cenário. Para que esses efeitos pudessem ser encontrados e entendidos, foi criada uma *task force*, da qual a Autora deste trabalho participou, que também tinha como objetivo colocar uma nova política adaptada em vigor.

Após análise e formulação da nova política, adaptada ao período de pandemia, foram feitos cálculos de estimativas do número de aumentos de limite, do aumento médio, do VPL em 12 meses, do VPL em 99 meses e da taxa de aprovação da política, ou seja, qual porcentagem do número total de clientes da *Fintech X* iriam receber aumento. Foi feito o lançamento, e após um dia com a política no ar, percebeu-se que um número muito menor de

aumentos foi dado, em comparação com a estimativa feita, o que levou à uma investigação para identificar as possíveis causas dessa diferença.

Dentre as possíveis causas, tem-se: erro de execução, seja no serviço, que é quem de fato dá os aumentos aos clientes ou erro na hora de tornar o código ativo; erro no processo de ETL, que é quando de fato as decisões de aumento de limite da política são dados aos clientes pelo sistema de serviços; cálculo das estimativas feito de maneira errônea; falta de população que esteja configurada para receber aumentos da política padrão. Para identificar a causa desse problema, foi montado um pequeno time, composto pela Autora deste trabalho e mais dois analistas de negócios mais experientes.

A equipe verificou que a causa responsável era a falta de população disponível para receber aumentos da política padrão. Assim, em uma segunda etapa foram revistos todos os experimentos que estavam ativos, há quanto tempo e seu tamanho amostral, a fim de decidir se seria possível acabar com algum experimento. Em um terceiro momento, foi feito um estudo para redimensionar o tamanho dos experimentos e se existia alguma forma de execução diferente, a fim de poupar a população. Ainda nessa terceira fase, foi feito um estudo do custo que a *Fintech X* tem por cliente em cada um dos tipos de experimentos. Todos os detalhes das tarefas realizadas tanto pela *task force* quanto pelo time formado para revisão dos experimentos serão melhor detalhados nos capítulos seguintes.


4. Desenvolvimento da nova política de crédito Covid

A primeira tarefa da *task force* formada para observar e entender os efeitos do cenário pandêmico foi definir quais componentes da política e modelos seriam monitorados mais de perto e com maior cautela. Para esse monitoramento, foi criada, também, uma reunião semanal com o responsável geral da área de cartão de crédito da *Fintech X*. Os componentes da política que foram escolhidos para um monitoramento mais detalhado foram: o risco, valor da fatura do cliente quando este começasse a ficar atrasado, os gastos e a taxa de juros. Quanto aos modelos, todos passaram a ser monitorados com mais detalhes e os fatores mais relevantes para o modelo de risco também passaram a ter seu comportamento acompanhado com mais detalhes.

4.1. Monitoramento de componentes da política

O monitoramento do risco mostrou, como esperado, um aumento em relação à predição feita devido ao cenário com muitas incertezas. Foram feitas algumas estratificações na população para analisá-la de acordo com uma característica específica. A primeira levou em conta a profissão dos clientes, a qual é fornecida pelo próprio de maneira voluntária através do aplicativo. O raciocínio por trás dessa estratificação foi que, provavelmente, autônomos, microempreendedores e donos e funcionários de empresas de pequeno e médio porte seriam mais afetados.

Gráfico 8 – Risco por banda de modelo de risco e por profissão




Fonte: Elaborado pela Autora

Tal hipótese foi comprovada ainda nas primeiras semanas de quarentena, nas quais já é possível observar um aumento do risco. Esse aumento de risco ocorreu, principalmente, para os microempreendedores, como é possível observar no gráfico 8. Nos gráficos referentes ao monitoramento do risco, o zero no eixo vertical equivale à predição feita pelo modelo de risco. Em casos em que esse valor é maior do que zero o modelo errou para menos, ou seja, fez uma predição subestimada. E no caso de valores negativos, o modelo superestimou o risco.

Outra estratificação feita foi em relação à renda de cada cliente, a qual pode ser informada pelo próprio no aplicativo. Além disso, também é possível obter uma estimativa da renda com dados de *bureau*, mas a renda utilizada é calculada por um modelo próprio da *Fintech X*, que leva em consideração as duas outras citadas anteriormente. O raciocínio por trás dessa categorização é que aqueles com renda menor teriam um aumento de risco, o que também foi confirmado nas primeiras semanas de quarentena. Também foi feita uma análise separando a população pelo endereço de entrega do cartão, visto que há algumas regiões nas quais conhecidamente a população possui maiores dificuldades financeiras.

Gráfico 9 – Risco por banda de modelo de risco e por renda




Fonte: Elaborado pela Autora

Além das categorizações citadas anteriormente, também foram feitas as seguintes: clientes negativados em alguma instituição segundo dados de bureau, balanço da conta na *Fintech X*, utilização do limite, idade, pagamento da fatura via boleto ou direto da conta da *Fintech X*, portabilidade do salário para a *Fintech X*, montante transferido da conta da *Fintech*

X e se solicitou ou recebeu o auxílio do governo. Um ponto relevante em relação à primeira categorização citada neste parágrafo, é que os dados provenientes de bureaus em geral possuem um atraso de um mês, ou seja, o dado recebido esse mês é referente ao mês anterior. Dessas últimas categorizações citadas, as que mais chamaram atenção foram: clientes que transferiram montantes grandes de sua conta, pagamento da fatura via boleto ou direto da conta e balanço da conta, pois tiveram uma piora no risco maior do que a prevista inicialmente. Em alguns casos sendo até duas vezes maior do que a previsão.

Em relação ao monitoramento do valor da fatura do cliente quando este começasse a ficar atrasado, este componente foi normalizado em relação ao limite que o cliente dispunha em seu cartão de crédito no momento. Para comparar a mudança de comportamento nesse caso, foram utilizados os meses de janeiro e fevereiro de 2020. Ao contrário do esperado, os clientes começaram a atrasar o pagamento com uma utilização de seus limites menor do que nos dois primeiros meses do ano, quando ainda não havia se iniciado a quarentena no Brasil. O gráfico 10 mostra o exemplo para uma banda do modelo de gastos, onde o eixo vertical é a porcentagem de utilização do limite e no eixo horizontal estão os dias do mês.


Gráfico 10 – Porcentagem do limite utilizado no momento que o cliente inicia um atraso de pagamento



Fonte: Elaborado pela Autora

Para o monitoramento dos gastos foram feitos dois tipos de classificação, uma seguindo a mesma lógica usada em risco, de acordo com característica dos clientes, e outra em relação à categoria do tipo de gasto, se foi com lazer, com educação ou com farmácia, por exemplo. No primeiro tipo de classificação, foram levados em conta menos critérios do que no monitoramento de risco, foi utilizado apenas: idade, recebimento ou solicitação do auxílio emergencial do governo, renda e profissão.

Gráfico 11 – Variação dos gastos mês a mês nos últimos três anos




Fonte: Elaborado pela Autora

De maneira geral, como pode-se observar no gráfico acima, houve uma queda nos gastos de todos os clientes. A principal mudança de comportamento observada no monitoramento de gastos na classificação dos clientes por idade foi em clientes entre 24 e 35 anos, que diminuíram seu gasto médio. Quanto à classificação pelo recebimento ou solicitação do auxílio governamental não foi possível uma mudança comportamental evidente durante os primeiros meses de quarentena. Em relação à classificação por renda, pode-se observar que clientes com renda mais alta passaram a gastar menos do que sua média em anos anteriores. E, por fim, em relação à profissão, houve uma queda mais acentuada dos autônomos e microempreendedores.

A queda na taxa de juros é bastante comum em épocas de crise econômica como uma forma de estímulo à economia, pois facilita o acesso das pessoas ao crédito. O monitoramento da taxa de juros, cobrada aos clientes que atrasam pagamento da fatura do cartão, mostrou, como esperado, que houve uma queda em relação aos dois primeiros meses do ano. O início da queda se deu apenas em abril e é ainda mais perceptível em maio. No gráfico abaixo é possível ver como a taxa variou dia a dia nos primeiros cinco meses do ano.

Gráfico 12 – Variação da taxa de juros por dia nos primeiros meses do ano




Fonte: Elaborado pela Autora

4.2. Monitoramento dos modelos

O monitoramento do modelo de risco passou a ser feito mais detalhadamente, acompanhando de perto os componentes que possuem maior peso e que poderiam sofrer maiores alterações. Os componentes que foram acompanhados mais de perto foram: delinquência, que é quando um cliente atrasa pelo menos um dia o pagamento da fatura; utilização do limite; e gastos, sendo este último categorizado por tipo de estabelecimento. Quanto à delinquência, pode-se observar um aumento considerável, ultrapassando o limite superior, definido pela Fintech X, logo no início da pandemia em março.

Gráfico 13 – Monitoramento da delinquência



Fonte: Elaborado pela Autora

A utilização, quanto o cliente gasta em relação ao seu limite, é o principal componente do modelo de risco, assim, seu monitoramento próximo é muito importante para a *Fintech X*. Este componente vinha de um momento de alta, quando muitos clientes estavam usando mais seu limite do que a média, principalmente devido às festas de final de ano e carnaval. Logo no início da pandemia, ainda houve um leve aumento em março, porém, a partir do final desse mês houve uma grande queda.


Gráfico 14 – Monitoramento da utilização



Fonte: Elaborado pela Autora


Quanto ao monitoramento dos gastos, este foi dividido por categorias de estabelecimentos. As categorias consideradas na Fintech X são: eletrônicos, vestuário, supermercado, lazer, transporte, restaurante, serviços, educação, casa, saúde e outros. Algumas categorias tiveram um aumento considerável, sendo as que mais se destacam saúde e supermercado. Enquanto outras, como lazer, vestuário e restaurantes, tiveram uma queda bastante alta. Essas mudanças são condizentes com a situação do momento de quarentena. Abaixo é possível observar nos gráficos as principais mudanças.

Gráfico 15 – Aumento de gastos na categoria Supermercado



Fonte: Elaborado pela Autora


Gráfico 16 – Diminuição de gastos na categoria Lazer



Fonte: Elaborado pela Autora

O monitoramento do modelo de risco propriamente dito foi feito através do AUC (*Area Under the Curve*), que é um indicador de performance bastante utilizado em *machine learning*. O valor do AUC varia de zero a um, sendo que o valor um significa que 100% das previsões feitas pelo modelo estão corretas. Esse tipo de análise é feito comparando a predição feita pelo modelo e dados reais do que realmente aconteceu. Um ponto relevante é que há uma censura em relação aos valores reais de quem se tornou inadimplente, pois são necessários 60 dias de atraso para poder ser computado. Dessa forma, há também uma censura no AUC do modelo. O gráfico abaixo foi gerado recentemente, de modo que já não há mais censura dos primeiros meses de quarentena. Nele é possível observar que houve uma queda de performance do modelo em relação à média que vinha tendo, porém a queda foi de apenas 2%. A maior queda ocorreu no mês de março, que foi quando se iniciou a quarentena no Brasil.

Gráfico 17 – AUC do modelo de risco




Fonte: Elaborado pela Autora

Quanto ao monitoramento do modelo de severidade, este é um modelo que possui um período de censura muito grande, que são os 180 dias considerados na construção do modelo. Devido a isso, no início da pandemia não foi possível observar grandes mudanças no comportamento dos clientes e nem dados relativos aos meses de início do cenário. Assim, esse monitoramento não foi de grande relevância e acabou sendo deixado de lado.

Para o monitoramento do modelo de gastos, foi utilizada a correlação de *Spearman* que é bastante usada para medir a performance de modelos de *machine learning*. Na correlação de *Spearman*, o valor varia entre menos um e um, sendo que quando as variáveis analisadas são inversamente proporcionais tem valor mais próximo a menos um e, caso contrário, valor mais próximo a um. Foi possível observar que a pandemia impactou negativamente a performance do modelo, principalmente no mês de início da quarentena, março. Nos meses seguintes, foi retornando à média de performance que tinha antes.

Gráfico 18 – Correlação de Spearman para o modelo de severidade



Fonte: Elaborado pela Autora

4.3. Formulação da nova política de crédito Covid

A partir dos comportamentos observados nos monitoramentos feitos, foi possível entender melhor quais mudanças estavam ocorrendo e ter percepções sobre como isso afetava a política e os modelos até então utilizados. Com isso, foram feitas hipóteses de possíveis mudanças nos modelos e na política a fim de adaptá-la ao período, sem que a *Fintech X* tivesse perdas financeiras por dar ou negar aumentos. As hipóteses criadas foram as seguintes: adaptação do modelo de risco, adicionar um multiplicador na curva de risco, adicionar um multiplicador na curva de gastos, otimizar a política para um prazo menor do que os 99 meses, adicionar bloqueios específicos por categorias.

A primeira hipótese, sobre adaptação do modelo de risco, foi trabalhada sobre os seguintes fatores: alterar a importância de componentes como a utilização, a delinquência e os gastos; retirar dados de negativados provenientes de *bureaus* que possuem atraso de um mês. Quanto à primeira opção, foram feitas simulações alterando a importância dos componentes citados anteriormente e observou-se que não havia uma grande diferença nas previsões do modelo. Este resultado é coerente, já que o modelo de risco leva em consideração em torno de 250 fatores diferentes, alterar a importância de poucos deles não possui um impacto tão grande no resultado final.

A motivação para retirar os dados de negativados provenientes de *bureaus* do modelo de risco se deu pois os dados recebidos eram relativos ao mês anterior. Dessa forma, havia um atraso em relação à real situação do cliente, o que poderia impactar o risco previsto: poderia ser previsto uma probabilidade de risco menor do que a real de um cliente que já estava negativado. O modelo, que foi chamado de modelo de risco 2 covid, foi construído e treinado, sem dados de negativados de *bureaus* e calculado seu AUC. Ao fazer a comparação deste modelo com o até então utilizado (modelo de risco 2) foi possível observar que sua performance era pior, como esperado, já que haviam sido retiradas algumas informações relevantes. Entretanto, ao comparar com o modelo anterior, o modelo de risco 1, o modelo de risco 2 covid possui uma performance melhor, como pode ser observado no gráfico 19 que compara o AUC dos três modelos citados.

Gráfico 19 – Comparação de AUC dos modelos de risco 1, 2 e 2 covid




Fonte: Elaborado pela Autora

A hipótese de acrescentar um multiplicador na curva de risco tem como objetivo ajustá-la melhor à realidade. Como citado no capítulo anterior, a curva de risco utilizada até o momento já possui um acréscimo de 10% em relação ao cálculo real. Por isso, quando esta hipótese foi levantada não houve uma grande aceitação por parte do responsável pela área de cartão de crédito. Outra sugestão dada foi adicionar um multiplicador no próprio risco calculado, deixando-o mais conservador.

Em vista dos dados que estavam disponíveis até o momento, percebeu-se que seria necessário um aumento de risco de em torno de 60%, para deixá-lo mais fiel à nova realidade. Esse aumento foi dado especificamente no risco daqueles não delinquentes e para todas as bandas do modelo de risco. No gráfico 20 tem-se a comparação do novo risco calculado e do risco base por banda do modelo de risco.


Gráfico 20 – Alteração do risco com multiplicador



Fonte: Elaborado pela Autora

Quanto à adaptação da curva de gastos, foi observado, como pode ser visto no gráfico 21 que, com a pandemia, houve uma queda de gastos quando comparado ao mesmo período do ano anterior. Assim, foi levantada a hipótese de adicionar um multiplicador à curva de gastos. Quando a hipótese surgiu, havia dados de 2020 até a vigésima segunda semana do ano, quando a diferença era de aproximadamente 20%. E essa diferença estava caindo com o passar das semanas. Assim, uma redução de 15% foi proposta, visto que a tendência era a diferença diminuir até se estabilizar, mas não necessariamente chegar a zero. O ajuste foi aplicado para os gastos nos próximos 12 meses, considerando que após esse período o gasto se restabelecerá.

Gráfico 21 – Número de transações por semana do ano em 2019 e início de 2020



Fonte: Elaborado pela Autora

A hipótese de mudar o período para o qual a política proativa é otimizada, que atualmente é para 12 meses, mas que ainda tenha VPL positivo em 99 meses, era de otimizar a política para os mesmos 12 meses, mas com VPL ainda positivo em 36 meses. A motivação para essa hipótese é que o cenário de incerteza era apenas passageiro e iria durar em torno de três a seis meses. E, portanto, talvez não fizesse sentido continuar com a mesma otimização de antes para o novo cenário. Entretanto, em uma das reuniões semanais com o responsável pela área de cartão de crédito, quando esta hipótese foi citada, não houve uma boa aceitação e foi descartada sem que tenham sido feitos quaisquer cálculos.

Quanto à opção de adicionar bloqueios específicos por categoria, a ideia era adicionar bloqueios para as profissões mais afetadas, como os MEI, e de quem possuísse uma dívida maior ou muito próximo do valor da renda estimada. Porém, com as mudanças já feitas, de alteração do modelo de risco e ajustes adicionados ao risco e à curva de gastos, esses bloqueios não teriam efeitos práticos. Assim, descartou-se essa hipótese e mantiveram-se os bloqueios citados no capítulo anterior, que são os bloqueios padrões.

Com todas as mudanças propostas aprovadas, foi feita a nova política de crédito, que foi chamada de política covid. Para aprovação final da política, foram feitas estimativas dos resultados esperados considerando sete meses de política no ar. As métricas vistas foram: a taxa de aprovação, o VPL em 12 meses e em 99 meses, número de aumentos e valor do aumento médio. Essas estimativas são feitas sem considerar a população que está nos experimentos, e

seus valores encontram-se na tabela 3, junto com uma comparação das mesmas estimativas feitas para a versão vigente da política antes da pandemia.

Tabela 3 – Valores esperados de aumento com a política covid

Métrica	Valor Estimado	
	Política Versão 4	Política Covid
Taxa de Aprovação	20%	13%
Número de Aumentos	15 milhões	11 milhões
Aumento Médio	R\$ 720,00	R\$ 630,00
Aumento Total de Limite	R\$ 10,8 bilhões	R\$ 6,9 bilhões
NPV 12 meses	R\$ 235 milhões	R\$ 190 milhões
NPV 99 meses	R\$ 1,1 bilhões	R\$ 0,7 bilhões

Fonte: Elaborado pela Autora

Comparando os valores esperados com os da política que estava em vigor antes da pandemia, a política versão 4, pode-se perceber que é uma política mais conservadora. A política covid e todas as estimativas calculadas foram apresentadas num fórum chamado *credit committee*, no qual todas as decisões sobre alteração efetiva de políticas devem ser apresentadas e aprovadas. Por ter sido construída com supervisão próxima do responsável pelo cartão de crédito, não surgiram *follow-ups* para serem feitos e a política foi aprovada. Com isso, ela foi acrescentada à base de dados que passaria pelo processo de ETL e passaria a dar os aumentos aos clientes.

5. Problemas verificados na implantação da política de crédito covid

Sempre que uma nova política é colocada em produção, há um monitoramento para garantir que ela está sendo executada corretamente. No caso da política covid, após dois dias no ar, percebeu-se que a quantidade de aumentos que estavam sendo dados era muito menor do que a estimativa feita. Isso ocasionaria um custo para *Fintech X* e insatisfação ainda maior por parte dos clientes, por não estarem recebendo aumentos. Para entender o motivo dessa diferença considerável foram levantadas algumas hipóteses:

- erro de execução, seja no serviço, que é quem de fato dá os aumentos aos clientes ou erro na hora de tornar o código ativo;
- erro no processo de ETL, que é quando de fato as decisões de aumento de limite da política são dados aos clientes pelo sistema de serviços;
- cálculo das estimativas feito de maneira errônea;
- falta de população que esteja configurada para receber aumentos da política padrão;

As três primeiras hipóteses poderiam ser confirmadas ou descartadas de maneira rápida, por isso foram as primeiras a serem investigadas. Para a primeira hipótese, bastava fazer uma simulação num ambiente de testes e ver quais eram os resultados obtidos. Para o teste do código, tem-se a plataforma onde todos os códigos são testados, o *databricks*. Ao executar o teste, obteve-se o mesmo resultado do que havia acontecido, portanto não havia sido um erro de execução no teste. Quanto à possibilidade de erro de execução no serviço, a *Fintech X* possui um site no qual é possível acompanhar todos os dados que chegam ao serviço e compará-los com o que era esperado que chegasse a partir do código. Ao verificar a execução da política no serviço, também não havia erro.

Dessa forma, a análise passou para o erro no processo de ETL, que costuma ser comum. Para acompanhar como está o processo de ETL basta verificar se determinado *dataset* já passou pelo processo e se foi bem sucedido o processo. Assim como as verificações anteriores, essa também é bastante rápida e prática e, mais uma vez, não foi encontrado nenhum erro.

Quanto à hipótese de erro no cálculo das estimativas, a verificação é um pouco mais trabalhosa, quando comparada com as anteriores. Todas as estimativas são calculadas com um código já pronto, bastando colocar os *inputs* corretos para que ele calcule todas as estimativas. Assim, era necessário garantir que os *inputs* estavam corretos e inseridos nos locais certos.

Esses foram gerados mais uma vez e novamente testados. O resultado obtido nesse novo cálculo das estimativas teve o mesmo resultado que o cálculo feito anteriormente. Portanto, só restava uma hipótese para ser verificada.

Uma análise inicial e superficial sobre a possibilidade de haver falta de população configurada para receber aumentos da política padrão foi feita. Para isso foi utilizado um *dataset* da camada de experimentos de crédito e pode-se notar que havia apenas uma pequena parcela da população total que não estava em nenhum experimento, ou seja, que estava direcionada para política considerada padrão. Assim, foi identificado que a quantidade de experimentos que estavam ativos estava consumindo muitos clientes e, em alguns casos, impedindo que estes recebessem aumento.

5.1. Análise dos experimentos ativos

Com a confirmação de que o problema era a população que estava comprometida em experimentos, foram revistos todos os que estavam ativos: há quanto tempo estavam ativos, com qual população e qual parcela da população total estava afetada. Para isso, foi utilizado o *dataset* da *Credit Experiments Layer*, que retorna em qual experimento cada um dos clientes está naquela data e se o cliente está ativo ou divergente, caso esteja em algum experimento.

A análise apontou que existiam 34 experimentos ativos naquele momento, e que a população que não estava nem ativa e nem divergente em nenhum experimento representava apenas 6% da população total. A seguir, tabela 4 com os experimentos que estavam ativos, porcentagem da população que estava ativa em cada um deles, data de lançamento de cada um deles e duração prevista:

Tabela 4 – Experimentos ativos no momento em que o projeto foi realizado

Experimento	% População Ativa no Experimento	Data de lançamento	Duração prevista (em meses)
RL lançamento	0,06%	jul./2019	12
RL 1o lote	0,57%	ago./2019	12
RL 2o lote	0,44%	set./2019	12
RL 3o lote	0,79%	nov./2019	12
RL 4o lote	0,11%	dez./2019	12
RL 5o lote	0,09%	fev./2020	12
teste de limite controle	0,10%	nov./2019	12
teste de limite permanente	0,13%	nov./2019	12
teste de limite grupo de teste	0,25%	nov./2019	12
teste de limite controle bloqueado	0,89%	nov./2019	12
v2 controle estendido	1,51%	jun./2018	18
v2 controle liberado	1,58%	jun./2018	18
v2 increase and block estendido	0,70%	jun./2018	18
v2 increase and block liberado	2,85%	jun./2018	18
v2 teste	3,30%	jun./2018	18
v3 controle	2,39%	set./2019	12
v3 increase and block	2,13%	set./2019	12
v3 teste	3,90%	set./2019	12
v4 control and release	1,62%	fev./2020	12
v4 increase and block	2,80%	fev./2020	12
v4 covid control and release mês 1	1,89%	mar./2020	18
v4 covid control and release mês 2	2,15%	abr./2020	18
v4 covid control and release mês 3	0,91%	mai./2020	18
v4 covid increase and block mês 1	3,07%	mar./2020	18
v4 covid increase and block mês 2	3,42%	abr./2020	18
v4 covid increase and block mês 3	1,58%	mai./2020	18
v4 política severa <i>control and release</i> mês 1	4,79%	abr./2020	18
v4 política severa <i>control and release</i> mês 2	2,98%	mai./2020	18
v4 política severa <i>increase and block</i> mês 1	7,88%	abr./2020	18

Fonte: Elaborado pela Autora

Continuação Tabela 4 – Experimentos ativos no momento em que o projeto foi realizado

Experimento	% População Ativa no Experimento	Data de lançamento	Duração prevista (em meses)
v4 política severa <i>increase and block</i> mês 2	4,58%	mai./2020	18
RL política severa control and release	3,95%	mai./2020	12
RL política severa <i>increase and block highcap</i>	3,90%	mai./2020	12
RL política severa <i>increase and block</i>	3,92%	mai./2020	12
RL política severa teste	4,01%	mai./2020	18

Fonte: Elaborado pela Autora

Assim, após esse mapeamento de quais experimentos estavam ativos, foi marcada uma reunião com o *squad lead* para decidir se fazia sentido continuar com todos aqueles experimentos ativos ou se era possível encerrar alguns antes do previsto. Nessa reunião foram tomadas as seguintes decisões:

- Finalizar os experimentos da versão dois da política, pois já estavam ativos há muito tempo;
- Finalizar os experimentos da versão quatro com política severa, pois ela não seria mais utilizada;
- Diminuir a duração dos experimentos RL política severa para quatro meses, pois a política não seria mais utilizada, mas talvez ainda fosse possível obter alguns resultados com o experimento;
- Manter os experimentos RL, versão três da política, versão quatro da política e testes de limite;
- Revisão dos tamanhos amostrais utilizados e da duração prevista dos experimentos;

As quatro primeiras decisões eram fáceis e rápidas de serem colocadas em prática, pois bastava uma alteração no código que definia os experimentos para que a duração dos experimentos fosse diminuída. Quanto à última decisão, foi considerada como uma segunda etapa desse projeto, visando entender, principalmente, se os tamanhos amostrais utilizados faziam sentido ou se seria possível diminuí-los a fim, tanto de poupar população quanto de economizar dinheiro, visto que todo teste precisava de um controle.

5.2. Revisão do tamanho amostral dos experimentos ativos

Para verificar se seria possível reduzir o tamanho das amostras dos experimentos, foi necessário calcular o intervalo de confiança das principais métricas analisadas. Elas métricas são calculadas pela diferença entre o comportamento da população no teste em relação ao comportamento da população no controle. As métricas são:

- delta RAM (*Risk-Adjusted Margin*), que é basicamente o mesmo que o VPL, mas sem trazer a valor presente;
- delta perdas, sendo que perda é considerado o montante que o cliente não pagou após 60 dias de atraso;
- delta gastos;
- delta MGM (*member get member*), quantas pessoas um cliente no teste indicou em relação a um cliente no controle;
- delta risco, que é em relação à quantidade de pessoas que tornou-se inadimplente;
- delta *churn*, *churn* é considerado quando um cliente não efetuou nenhuma transação no cartão de crédito nos últimos três meses;
- delta utilização, quanto do seu limite o cliente gastou.

Uma análise de tamanho amostral de experimentos já havia sido feita anteriormente, por um analista de negócios e um cientista de dados, para um tipo de experimento específico. Essa análise foi utilizada como referência para avaliar os resultados da técnica para o cálculo do intervalo de confiança. Uma técnica de cálculo de intervalo de confiança através do *bootstrap* havia sido utilizada, mais especificamente o método de percentil. Com uma conversa com os dois responsáveis do projeto anterior e uma análise preliminar dos resultados, chegou-se à conclusão de que os resultados obtidos tinham sido bons e que seria recomendável aplicar a mesma técnica.

Assim, para o cálculo mais preciso do intervalo de confiança das métricas citadas acima, foi utilizado o método percentil do *bootstrap*. Nessa nova análise, foi utilizada como amostra mestre dados dos experimentos da versão dois da política.

O primeiro passo foi decidir quantas reamostragens seriam feitas para os cálculos dos intervalos de confiança de cada métrica. Para isso, com os dados dos experimentos da versão dois da política, foram simulados os cálculos da média e intervalos de confiança para a métrica

delta RAM, variando a quantidade de reamostras e utilizando tamanho amostral de controle igual a 5000 e de teste igual a 10000. As métricas foram calculadas cinco vezes para cada quantidade de reamostra, a fim de entender com qual quantidade a diferença dos valores obtidos poderia ser considerada quase inexistente. Foi considerado como uma diferença quase inexistente quando as métricas calculadas em cada uma das cinco vezes estivessem com pelo menos as três primeiras casas decimais iguais. Foram utilizadas as seguintes quantidades de reamostras: 500, 1000, 1500 e 2000. Os valores obtidos para média e intervalo de confiança em cada uma das vezes que foram feitas estão na tabela 5, a seguir:

Tabela 5 – Valores da métrica delta_ram variando quantidade de reamostragens

Quantidade de Reamostras	Tamanho do Teste	Tamanho do Controle	Métrica	Média	IC Superior	IC Inferior
500	10000	5000	delta_ram	14,214325	25,445412	2,98324
500	10000	5000	delta_ram	14,213861	25,443435	2,98429
500	10000	5000	delta_ram	14,209874	25,445523	2,97423
500	10000	5000	delta_ram	14,207832	25,442124	2,97354
500	10000	5000	delta_ram	14,219423	25,444241	2,99460
1000	10000	5000	delta_ram	14,213786	25,444036	2,98354
1000	10000	5000	delta_ram	14,213926	25,444396	2,98346
1000	10000	5000	delta_ram	14,213438	25,444213	2,98266
1000	10000	5000	delta_ram	14,213213	25,444328	2,98210
1000	10000	5000	delta_ram	14,213543	25,444092	2,98299
1500	10000	5000	delta_ram	14,213413	25,444077	2,98275
1500	10000	5000	delta_ram	14,213312	25,444132	2,98249
1500	10000	5000	delta_ram	14,213391	25,444121	2,98266
1500	10000	5000	delta_ram	14,213423	25,444021	2,98283
1500	10000	5000	delta_ram	14,213453	25,444096	2,98281
2000	10000	5000	delta_ram	14,213786	25,444033	2,98354
2000	10000	5000	delta_ram	14,213926	25,444102	2,98375
2000	10000	5000	delta_ram	14,213438	25,444094	2,98278
2000	10000	5000	delta_ram	14,213213	25,444124	2,98230
2000	10000	5000	delta_ram	14,213543	25,444045	2,98304


Fonte: Elaborado pela Autora

Além dos valores da métrica, também foi observado o tempo de processamento, que, como esperado, aumentou com o número de remostras feitas. Assim, pensando que seriam calculadas ao todo sete métricas, o ideal seria escolher uma quantidade de reamostras com tempo de processamento razoável. Dessa forma, a partir dos dados, foi decidido seguir com a quantidade de reamostras igual a 1000, pois já apresentava uma variação suficientemente pequena para as métricas e os cálculos seriam feitos mais rapidamente. Para os cálculos realizados acima e todos os demais que serão realizados neste projeto, foi utilizada a linguagem de programação Python. O código utilizado encontra-se no apêndice 1.

Definida a quantidade de reamostras que seriam feitas, o passo seguinte foi determinar para quais tamanhos de amostras seriam calculadas as métricas. Os tamanhos amostrais utilizados até então eram de 50.000 clientes elegíveis a receber aumento no primeiro mês para o teste e o *increase and block* e de 30.000 clientes que estivessem elegíveis a receber aumento no primeiro mês para os controles. Como a ideia inicial era diminuir o tamanho amostral, foi decidido que os cálculos seriam feitos para 10.000, 20.000, 30.000, 40.000 e 50.000 clientes para os testes, e de 5.000, 10.000, 15.000 e 30.000 para os controles. O nível de confiança utilizado foi 95%, assim, com o uso do método percentil de *bootstrap*, foram calculados os percentis 2,5% e 97,5%.


Foram calculados a média e os limites do intervalo de confiança para todas as métricas analisadas nos experimentos. Para facilitar a interpretação dos resultados e conseguir comparar de maneira mais fácil as diferenças entre os tamanhos amostrais, todas as estatísticas - média, limite inferior e limite superior - foram divididas pela média e subtraído um. Dessa forma, a média é sempre uma linha no eixo x com y igual a zero e as linhas dos limites mostram a precisão que o intervalo de confiança tem com tais tamanhos amostrais. Foram plotados gráficos com eixo x sendo o tamanho amostral dos testes e *increase and block*, eixo y sendo a precisão do intervalo de confiança e um gráfico para cada um dos quatro tamanhos amostrais do controle.

Gráfico 22 – Precisão do Intervalo de Confiança conforme variação dos tamanhos amostrais



Fonte: Elaborado pela Autora

Continuação Gráfico 22 – Precisão do Intervalo de Confiança conforme variação dos tamanhos amostrais




Fonte: Elaborado pela Autora

Após uma análise inicial dos intervalos de confiança com um tamanho amostral menor do que o utilizado até o momento, percebeu-se que o intervalo de confiança era mais abrangente, como esperado. Entretanto, a diferença no intervalo de confiança gerou uma insegurança sobre a alteração do tamanho de todos os experimentos, pois se perderia a precisão que se tinha até então. Uma hipótese surgiu, principalmente para os experimentos do tipo *increase and block* que são lançados mensalmente, foi a de reunir os dados de dois ou mais experimentos e analisá-los juntos como se fossem de um só. No caso da hipótese ser confirmada, isso dará maior confiança em diminuir os tamanhos amostrais utilizados.

Para análise dessa nova hipótese, foram consultados outros times da *Fintech X* que tinham mais experiência com estatística, a fim de entender se a hipótese era verdadeira ou não. Um ponto levantado nessa discussão foi que, com a junção de dados de experimentos realizados em meses diferentes, perderia-se o fator relacionado à sazonalidade do comportamento do cliente. Do ponto de vista estatístico não havia nenhum impeditivo ao analisar mais de um experimento em conjunto, entretanto havia a ressalva a respeito da sazonalidade.

Dessa forma, foram calculados também o intervalo de confiança considerando tamanho amostral do controle igual a 60.000 e tamanho amostral do teste igual a 100.000, o que equivale a dois experimentos com os tamanhos amostrais usados até então. Essa etapa foi feita apenas para ter uma noção de quanto seria o intervalo de confiança juntando considerando dois experimentos analisados como um só, pois ainda não foi feita levando em conta os novos tamanhos amostrais.

Gráfico 23 – Precisão do Intervalo de Confiança considerando dois experimentos como um só




Fonte: Elaborado pela Autora

Com todos esses dados calculados, foi possível fazer uma análise melhor de qual seria o intervalo de confiança ideal para seguir. A primeira decisão foi quanto ao tamanho dos experimentos de controle. Esse tipo de experimento é bastante caro para a *Fintech X*, além de ser ruim para o relacionamento com os clientes, já que eles ficam sem receber qualquer aumento em seu limite do cartão de crédito. Os custos de cada um dos experimentos será melhor explicado e detalhado mais à frente. Outro fator levado em conta foi quantos experimentos seriam necessários para chegar no tamanho amostral utilizado até então. Caso o novo tamanho amostral fosse de 5.000 seriam necessários seis experimentos, ou seja, meio ano. No caso do tamanho amostral 10.000, seriam necessários apenas três e para o tamanho amostral de 15.000, apenas dois experimentos. Devido a esses fatores, e comparando as diferenças entre os intervalos de confiança calculados para cada tamanho amostral do grupo de controle proposto, decidimos seguir com tamanho amostral de 10.000.

Com o tamanho amostral do grupo de controle, o passo seguinte foi a definição do tamanho amostral do grupo de teste. Como é possível observar no gráfico 22 para o tamanho amostral do grupo de controle igual a 10.000, a inflexão da curva ocorre entre 15.000 e 20.000 para o tamanho amostral do grupo de teste. Além disso, assim como para definição do tamanho amostral, também foi levado em conta quantos experimentos seriam necessários para chegar ao

mesmo tamanho utilizado até então. Devido a esses fatores, decidiu-se seguir com tamanho amostral de 20.000. Nos gráficos abaixo é possível comparar lado a lado a precisão dos intervalos de confiança com os novos tamanhos amostrais e os tamanhos até então utilizados para as métricas de delta gastos e delta RAM.


Gráfico 24 – Precisão do Intervalo de Confiança com novos tamanhos amostrais e antigos



Fonte: Elaborado pela Autora

Assim, houve diminuição para um terço do tamanho amostral do grupo de controle e para dois quintos do tamanho amostral do grupo de teste, o que implica que com três pares de experimentos volta-se a ter um intervalo de confiança semelhante ao que se tinha até o momento. Essas decisões foram tomadas pelos responsáveis pelo projeto, ainda era necessária aprovação do responsável pela *Credit Tribe* para que os tamanhos amostrais fossem de fato mudados, por tratar-se de uma mudança consideravelmente grande e impactante. A fim de assegurar que as decisões fossem aceitas, também foram feitos gráficos considerando tamanho amostral do grupo de controle igual a 120.000 e do grupo de teste igual a 240.000, o que equivale a um ano inteiro de experimentos realizados mensalmente.

Gráfico 25 – Precisão do Intervalo de Confiança com novos tamanhos amostrais




Fonte: Elaborado pela Autora

Além disso, para dar um maior embasamento para a tomada de decisão, foram calculados os custos que cada tipo de experimento tem para a *Fintech X*. Os tipos de experimento que são possuem custos para a *Fintech X* são aqueles que deixam de dar aumentos para os clientes. Para essa análise foram levados em consideração apenas os experimentos recorrentes, que no caso são: os de controle e os *increase and block*.

Para o cálculo dos custos dos experimentos foram considerados o delta VPL que o grupo de teste tem em relação ao grupo de controle durante o período do experimento, ou seja, no curto prazo e o delta VPL no longo prazo. Para o delta VPL no curto prazo, foram utilizados dados de experimentos antigos e foi calculado o VPL médio por cliente até o mês 18 após o início do experimento para o grupo de controle, o grupo de *increase and block* e o grupo de teste. Considerou-se como padrão o VPL do grupo de teste, que não deixou de receber aumento em nenhum momento do experimento e, desse valor, foi subtraído o VPL do grupo de *increase and block* para calcular o custo no curto prazo para essa população e o mesmo foi feito para o grupo controle. No gráfico abaixo é possível ver que o grupo de controle possui um custo mais elevado, visto que não recebe aumento em nenhum momento do experimento, enquanto o grupo

de *increase and block* tem um custo menor, já que recebem aumento no primeiro mês do experimento.

Gráfico 26 – Custo por cliente acumulado por mês para experimentos de controle e *increase and block*



Fonte: Elaborado pela Autora

Apesar do cálculo ter sido feito para 18 meses, é considerado como curto prazo apenas os 12 primeiros meses. Assim, o custo foi de aproximadamente R\$10 por cliente para o grupo de *increase and block* e de R\$30 por cliente para o grupo de controle. O custo no curto prazo pode ser calculado de maneira mais precisa do que no longo prazo, pois havia dados suficientes. Já para o cálculo do custo no longo prazo, não havia dados reais para o cálculo, então foi feita uma estimativa comparando o VPL estimado em 99 meses para os grupos de teste, de controle e de *increase and block*. Para calcular o VPL estimado em 99 meses, foram utilizados os dados dos mesmos experimentos usados no cálculo do curto prazo. Todos os VPL foram estimados utilizando um código pronto, o mesmo utilizado nos cálculos das estimativas das políticas e chegou-se aos custos de aproximadamente R\$20 por cliente para o grupo de *increase and block* e de R\$60 por cliente para o grupo controle. Somando o custo no curto e no longo prazo, chegou-se ao custo total de R\$30 por cliente para o *increase and block* e de R\$90 por cliente para o controle.

Tabela 6 - Custo por cliente acumulado por mês para experimentos de controle e *increase and block*

	Tipo de Experimento	Increase and Block	Controle
Custo por cliente	Curto Prazo	R\$10,00	R\$30,00
	Longo Prazo	R\$20,00	R\$60,00
	Total	R\$30,00	R\$90,00
Tamanho Amostral	Atual	50 000	30 000
	Proposta	20 000	10 000
Custo do Experimento	Atual	R\$1.500.000,00	R\$2.700.000,00
	Proposta	R\$600.000,00	R\$900.000,00
Economia por Experimento		R\$900.000,00	R\$1.800.000,00

Fonte: Elaborado pela Autora

Assim, com a mudança de tamanho amostral proposta, a *Fintech X* economizaria cerca de 2,7 milhões de reais por parte de experimento *increase and block* e controle. Considerando que um dos OKRs do time de CLP é lançar esse tipo de experimento mensalmente, a economia anual seria de 32,4 milhões de reais.

Durante a execução do projeto uma outra hipótese foi levantada que seria de aumentar o período de elegibilidade dos experimentos do tipo *increase and block* de um mês para dois meses. Com esta hipótese, visava-se a diminuição da população comprometida com experimentos e não uma redução de custos, pois dois experimentos passariam a ter exatamente a mesma população divergente. Para validar essa hipótese, era preciso saber se o número de aumentos dados pela política variava muito de um mês para outro.

No processo de validação, foram utilizados dados do experimento *increase and block* da versão 3 da política e a base de dados onde são armazenados todos os aumentos que já foram dados. Num primeiro momento foi calculado quantos clientes que estavam no experimento receberam um aumento no primeiro mês de experimento, ou seja, aqueles que ficaram de fato ativos. Em seguida, foi calculado quantos clientes receberam um aumento no mês seguinte, a fim de entender se a quantidade de aumentos para aquela população havia mudado ou se mantido a mesma. Essa primeira análise teve como resultado um número de aumento bem semelhante no primeiro e segundo mês. Porém, poderia tratar-se de uma semelhança pontual, então, para garantir a validação da hipótese, os mesmos cálculos foram feitos com dados do experimento de *increase and block* de outra versão da política, mais especificamente a versão 2. Esse segundo cálculo confirmou o resultado obtido no primeiro.

Tabela 7 – Número de Aumentos no primeiro e segundo mês de experimentos *increase and block*

Experimento	Métrica/Mês	1º Mês	2º Mês
v2 increase and block	Números de Aumentos	34 000	28 000
	Taxa de Aprovação	12,67%	10,56%
v3 increase and block	Números de Aumentos	35 000	38 000
	Taxa de Aprovação	11,13%	11,65%

Fonte: Elaborado pela Autora

Assim, decidiu-se realizar também essa alteração na forma como os experimentos são feitos, a fim de poupar população para que não ocorra novamente o mesmo problema que ocorreu na implementação da política covid. Todas as alterações propostas foram apresentadas num fórum chamado *Credit Checkpoint* e aprovadas com uma ressalva. A ressalva era de que caso fosse o primeiro experimento realizado com a política, no caso dos experimentos recorrentes, deveria ser feito com o tamanho amostral que era usado até então, mas podendo ter uma duração menor, mas de pelo menos seis meses.

5.3. Resultados da revisão dos experimentos

Com a aprovação das mudanças feitas nos experimentos, incluindo o término de alguns deles e as diminuições de tamanho amostral, grande parte da população foi liberada e ficou sujeita aos aumentos da política covid, que era a política padrão no momento. O número de experimentos ativos foi reduzido de 34 para 25, com o término dos experimentos decididos na reunião com o *squad lead*. E os tamanhos amostrais, como dito no capítulo anterior, mudaram de 30.000 para 10.000 nos grupos de controle e de 50.000 para 20.000 nos grupos de teste.

Considerando apenas a primeira mudança feita, do término de alguns experimentos, uma boa parcela da população já foi liberada. Esta primeira etapa foi realizada ainda no mês de junho de 2020. Apenas com isso, os números de aumentos dados pela política covid já se aproximaram das estimativas feitas inicialmente, porém ainda uma diferença considerável. Levando em consideração também a mudança nos tamanhos amostrais, posta em prática no mês de julho de 2020, o número de aumentos e a soma dos aumentos de limite dados pela política covid ficaram ainda mais próximos das estimativas feitas e mostradas na tabela 3. Além disso, o número de pessoas designadas à política passou de 6%, antes das mudanças nos experimentos, para 35%. Na tabela abaixo é possível ver como foram alteradas as porcentagens da população na política padrão, divergente e ativa devido às mudanças feitas.


Tabela 8 – Variação das populações em experimento

	Antes das mudanças	Depois das mudanças
População na política padrão	6%	35%
População divergente	19%	21%
População ativa	75%	44%

Fonte: Elaborado pela Autora

Ter uma política proativa vigente e um número grande de clientes impactados por ela fazia parte do primeiro OKR definido pelo *squad*, portanto todo esse projeto foi de suma importância estratégica para a *Fintech X*. Havia três resultados-chave associados a esse OKR e, com o projeto da política covid, dois desses resultados foram atingidos: ter uma política proativa novamente no ar e impactar ao menos um milhão de clientes com políticas em resposta à crise. Como pode-se ver no gráfico abaixo, no mês de abril e maio o número de aumentos dados foi muito abaixo da média dos meses anteriores e, em junho e julho, com a reativação da política o número voltou a crescer e atingiu-se o objetivo almejado. Vale ressaltar que nos meses de abril e maio, apesar de não ter nenhuma política proativa e reativa vigentes, ainda foram dados aumentos aos clientes que estavam em experimentos nos grupos de teste.

Gráfico 27 – Número de aumentos dados por mês



Fonte: Elaborado pela Autora

O fato da política de crédito ter permanecido desativada por quase dois meses fez com que alguns aumentos ficassem represados. Ao tornar a política ativa novamente, após liberação da população dos experimentos, houve um grande número de aumentos, o que explica a alta de aumentos nos meses de junho e julho, chegando até a superar a média dos meses anteriores à crise. Além dos aumentos represados, outro fator que impactou no número de aumentos foi a liberação de uma parte considerável da população dos experimentos. Os aumentos dados tiveram uma aceitação muito boa por parte dos clientes da *Fintech X*, levando-os até a comentar sobre eles em suas redes sociais.

Além do OKR relacionado à política de crédito no período de crise, também foi trabalhado o OKR que dizia respeito a realização de experimentos de *increase and block* mensalmente. Com todas as mudanças propostas e aceitas, houve uma grande diminuição nos custos, próxima a 30 milhões de reais ao ano, para que esse OKR fosse atingido. Além disso, também houve uma diminuição da população comprometida com experimentos no longo prazo.

Esse projeto teve, também, um grande impacto ao reavaliar processos que não eram revistos há muito tempo, como é o caso dos tamanhos amostrais dos experimentos. Quanto à diminuição da população nos experimentos, caso se mantivessem os tamanhos amostrais até então utilizados, praticamente a população inteira ficaria comprometida em experimentos em pouco tempo.

Tabela 9 – Comprometimento da população com experimentos

	Antes das mudanças	Depois das mudanças
População bloqueada pelo Increase and block e controle	960 000	360 000
População divergente em experimentos (considerando taxa de aprovação de 15%)	6400 000	2400 000

Fonte: Elaborado pela Autora

Na tabela acima é possível ver a diferença entre a população que estaria comprometida sem as mudanças nos tamanhos amostrais e com as mudanças, considerando apenas o lançamento de experimentos de *increase and block* mensalmente, ou seja, sem considerar outros experimentos já existentes ou que pudessem surgir. Lembrando que um experimento de *increase and block* inclui a população em teste e uma população em controle, o que consome o equivalente a 30.000 para o lançamento dos dois grupos.

Considerando todos os resultados obtidos e os OKRs que puderam ser atingidos, os projetos descritos neste trabalho foram de suma importância para a *Fintech X* no período em que foram realizados.

6. Conclusão

As *fintechs* têm ganhado uma relevância cada vez maior no mercado de serviços financeiros brasileiro, na medida em que desafiam as grandes instituições financeiras a repensarem seus modelos de negócio, o seu portfólio de produtos e o nível de serviço que desempenham. A agilidade do modo de operação dessas startups faz com que mudanças organizacionais ou iniciativas inovadoras sejam conduzidas de forma mais rápida e menos burocrática dentro dessas organizações.

Em um cenário de pandemia, onde muitas incertezas surgiram, essa agilidade no modo de operação foi essencial para acelerar o processo de adaptabilidade a um cenário como esse. Inicialmente partiu-se da necessidade de lidar entender como o cenário pandêmico, no qual o mundo se viu envolvido, afetava a política de crédito e seus componentes e com qual impacto. Para isso, foram feitos monitoramentos dos modelos utilizados na política de crédito e de componentes diretos da política.

Em seguida, com uma noção dos impactos causados, foram sugeridas uma série de mudanças na política para que ela tomasse decisões mais assertivas para o período pelo qual estávamos passando. Todas as sugestões foram testadas e levadas ao time mais sênior para avaliar quais de fato eram importantes e faziam sentido. E, assim, foram priorizadas as sugestões que mais se adequavam às necessidades.

Após a construção da política, ao colocá-la em produção, foi observada uma inconsistência no número de aumentos dados em relação às estimativas feitas. Essa inconsistência levou à revisão de processos que não eram revistos há um bom tempo. Foi observado que apenas uma pequena parcela da população estava direcionada à política padrão. Por isso, foram revistos todos os experimentos que estavam sendo realizados pela *Fintech X* em relação ao limite do cartão de crédito e se os tamanhos amostrais utilizados faziam sentido.

Como é possível verificar pelos resultados apresentados no capítulo anterior, esse projeto como um todo foi de grande importância para *Fintech X*. Auxiliando no cumprimento de OKRs definidos exclusivamente para o período de pandemia e, até, na redução de custos para que esses objetivos pudessem ser atingidos.

Por fim, além de todo o conhecimento em tópicos diversos em Engenharia de Produção adquirido pela Autora durante a realização deste trabalho - desde conceitos já bastante tradicionais na literatura como Estatística até temas mais modernos e recentes, como Gestão

Ágil - espera-se que as contribuições relatadas influenciem positivamente no processo de revisão constante dos processos já instaurados e consolidados, visto que em muitos casos há espaço para redução de custos e otimização do processo. Além, é claro, do impacto para sociedade brasileira com os aumentos de limite que foram dados durante um período tão complicado quanto o que se estava passando no momento.

REFERÊNCIAS BIBLIOGRÁFICAS

ABRAHAMSSON, P. et al. **Agile Software development methods: Review and analysis**. VVT publications 478, Espoo/FL, 2002.

ASSAF NETO, A. **Mercado Financeiro**. 12. ed. São Paulo: Atlas, 2014

BERTSEKAS, D. **Dynamic programming and optimal control: Approximate dynamic programming**. Athena Scientific, IL, 2012

BLATT, A. **Avaliação de risco e decisão de crédito: um enfoque prático**. São Paulo: Nobel, 1999.

BÚSSOLA DO INVESTIDOR. **Níveis de Governança Corporativa na Bovespa**. Disponível em: <<https://www.bussoladoinvestidor.com.br/niveis-governanca-corporativa-bovespa/>>. Acesso em 03 de Novembro de 2020.

CAOINETTE, J. B.; ALTMAN, E. I.; NARAYANAN, P. **Gestão do risco de crédito: o próximo grande desafio financeiro**. Rio de Janeiro: Qualitymark, 2000.

CASTRO NETO, José Luís de; SÉRGIO, Renata Sena Gomes. **Análise de Risco e Crédito**. Curitiba: IESDE Brasil S.A., 2009

CHAIA, A. J.. **Modelos de Gestão do risco de Crédito e sua Aplicabilidade no Mercado Brasileiro**, 2003. 90f. Dissertação (Mestrado em Administração) – Faculdade de Economia, Administração e Contabilidade, Universidade de São Paulo, São Paulo, 2003.

COMPUTER WORLD. **Brasil, o país das Fintechs: panorama do setor para 2020**. Disponível em: <<https://computerworld.com.br/2020/02/10/brasil-o-pais-das-fintechs-panorama-do-setor-para-2020/>>. Acesso em 01 de Julho de 2020.

COSTA NETO, Pedro Luiz de Oliveira. **Estatística**. São Paulo: Edgard Blucher, 2002.

DAVISON, A. C.; HINKLEY D. V.. **Bootstrap methods and their application**. Cambridge: Cambridge University Press, 2008.

DEVORE, Jay L.. **Probabilidade e Estatística: para engenharia e ciências**. São Paulo: Cengage Learning, 2006

DISTRITO. **São Paulo concentra 83% dos investimentos de Venture Capital do país.**

Disponível em: <<https://distrito.me/sao-paulo-venture-capital/>>. Acesso em 01 de Julho de 2020.

EFRON, B.; TIBSHIRANI, R. J. **An introduction to the bootstrap.** New York: John Wiley& Sons, 1993.

GIRYES, R.; ELAD, M. **Aprendizagem por Reforço: A Survey.** 2011

GITMAN, Lawrence. J. **Princípios administração financeira.** 12. ed. São Paulo: Pearson Prentice Hall, 2010.

INTERNET LIVE STATS. Disponível em: <<https://www.internetlivestats.com/one-second/>>. Acesso em 28 de Outubro de 2020.

MANKIW, N. Gregory. **Introdução à Economia.** 6. ed. São Paulo: Cengage Learning, 2014

MOHRI, M.; ROSTAMIZADEH, A.; TALWALKAR, A. **Foundations of Machine learning.** [S.l.]: The MIT Press, 2012.

MONTGOMERY, D. C.; RUNGER, G. C. **Estatística aplicada e probabilidade para engenheiros.** 2. ed. Rio de Janeiro: LTC, 2003.

PROCON. **Código de Proteção ao Consumidor celebra 30º aniversário.** Disponível em:<<http://www.procon.mt.gov.br/-/15374045-codigo-de-protecao-e-defesa-do-consumidor-celebra-30-aniversario>>. Acesso em 03 de Novembro de 2020.

QIU, J.; WU, Q.; DING, G; et al. **A survey of machine learning for big data processing.** EURASIP J. Adv. Signal Process. 2016, 67 (2016). Disponível em: <<https://doi.org/10.1186/s13634-016-0355-x>>. Acesso em: 14 de Outubro de 2020

RUSSON, Philip. **Big Data Analytics.** The Data Warehouse Institute (TDWI), 2011

SAUNDERS, Antonhy. **Medindo o Risco de Crédito – Novas Abordagens para o Value at Risk e Outros Paradigmas,** Rio de Janeiro: Qualitymark, 2000.

SANTOS, José Odílio dos; FAMA, Rubens. **Avaliação da aplicabilidade de um modelo de credit scoring com variáveis sistêmicas e não-sistêmicas em carteiras de crédito bancário rotativo de pessoas físicas.** *Rev. contab. finanç.,* São Paulo, v. 18, n. 44, p. 105-117, Aug. 2007.

SCHRICKEL, Wolfgang Kurt. **Análise de Crédito,** 4. Ed. São Paulo: Atlas, 2000.

SECURATO, J.R. (Coord.) **Crédito: Análise e Avaliação de Risco: Pessoas Físicas e Jurídicas**. São Paulo: Saint Paul, 2002.

SILVA, J. P. da. **Gestão e análise de risco de crédito: intermediação financeira e banco múltiplo**. 4. ed. São Paulo: Atlas, 2003.

SAGIROGLU, S.; SINANC, D. **Big data: A review**, *2013 International Conference on Collaboration Technologies and Systems (CTS)*, San Diego, CA, 2013, pp. 42-47, doi: 10.1109/CTS.2013.6567202

TCJE, Estado do Ceará Poder Judiciário. **A importância da Lei de Recuperação Judicial e Falência na economia brasileira**. Disponível em: <<https://www.tjce.jus.br/noticias/a-importancia-da-lei-de-recuperacao-judicial-e-falencia-na-economia-brasileira/>>. Acesso em 03 de Novembro de 2020.

APÊNDICE

1. Código para cálculo dos intervalos de confiança utilizando método Bootstrap

```
number_of_iterations = 1000
confidence_interval = 0.95
two_tail_conf = (1-confidence_interval)/2
start_range_test = 10000
end_range_test = 100001
start_range_control = 120000
end_range_control = 120001
step_control = 5000
step_test = 10000
metrics_to_read = list(filter(lambda col: col not in ["account__id",
                                                    "next_pv",
                                                    "cum_2_months_pv",
                                                    "cum_3_months_pv",
                                                    "churn_flag_bill",
                                                    "account_churn_flag",
                                                    "score_date",
                                                    "experiment_log",
                                                    "bills_after_score"],
                              v2_experiments.columns))

control_size = [10000,30000]
bills_after_score = [6]
```

```

metrics = {
    "test_size": [],
    "control_size": [],
    "metric": [],
    "bills_after_score": [],
    "metric_mean": [],
    "metric_upper_bound": [],
    "metric_lower_bound": [],
}

v2_test_customers = v2_experiments[v2_experiments.experiment_log == "v2_ib"]
v2_cont_customers = v2_experiments[v2_experiments.experiment_log == "v2_ib_control"]

for bill in bills_after_score:
    v2_experiments.loc[v2_experiments.bills_after_score == bill]
    print("bill ", bill)
    for n_control in range(start_range_control, end_range_control, step_control):
        print("control size ", n_control)
        for n_test in range(start_range_test, end_range_test, step_test):
            print("test size ", n_test)
            metric_dict = {}

            for metric_list_key in metrics_to_read:
                print(metric_list_key)

                for iteration in range(number_of_iterations):
                    ### Getting the metric for the select population
                    v2_control_metric = np.nanmean(
                        np.random.choice(
                            v2_cont_customers
                                [metric_list_key]
                                .values,
                            n_control,
                            replace=True
                        )
                    )
                    v2_test_metric = np.nanmean(
                        np.random.choice(
                            v2_test_customers
                                [metric_list_key]
                                .values,
                            n_test,
                            replace=True
                        )
                    )

```

```
delta = v2_test_metric-v2_control_metric
percentage = v2_test_metric/v2_control_metric

metric_dict.setdefault(metric_list_key, []).append(delta)

for metric_list_key in metrics_to_read:
    mean = np.mean(metric_dict[metric_list_key])
    up_b = np.quantile(metric_dict[metric_list_key], 1 - two_tail_conf)
    lw_b = np.quantile(metric_dict[metric_list_key], two_tail_conf)

    metrics["test_size"].append(n_test)
    metrics["control_size"].append(n_control)
    metrics["metric"].append(metric_list_key)
    metrics["bills_after_score"].append(bill)
    metrics["metric_mean"].append(mean)
    metrics["metric_upper_bound"].append(up_b)
    metrics["metric_lower_bound"].append(lw_b)
```