

BRUNO AKIRA KOBAYASHI

GANHO DE ESCALABILIDADE E MELHORIA OPERACIONAL NA PREVENÇÃO À  
LAVAGEM DE DINHEIRO DE UMA FINTECH

São Paulo

2019



BRUNO AKIRA KOBASATO

GANHO DE ESCALABILIDADE E MELHORIA OPERACIONAL NA PREVENÇÃO À  
LAVAGEM DE DINHEIRO DE UMA FINTECH

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

São Paulo

2019



BRUNO AKIRA KOBASATO

GANHO DE ESCALABILIDADE E MELHORIA OPERACIONAL NA PREVENÇÃO À  
LAVAGEM DE DINHEIRO DE UMA FINTECH

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

Orientador: Prof. Dr. Guilherme Ary Plonski

São Paulo

2019

## FICHA CATALOGRÁFICA

Sato, Bruno Akira

Ganho de escalabilidade e melhoria operacional na prevenção à lavagem de dinheiro de uma fintech / B. A. Sato -- São Paulo, 2019.

136 p.

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

1.Métodos Ágeis 2.Tecnologia da Informação 3.Compliance I.Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia de Produção II.t.

*Ao meu irmão, por me ensinar a sonhar, e  
aos meus pais, por viabilizarem o caminho.*





## **AGRADECIMENTOS**

Ao meu irmão, cuja sede inesgotável por conhecimento me inspira a evoluir.

Aos meus pais, cujo carinho e sabedoria sem fronteiras servem de alicerce para quem sou hoje.

Ao professor Ary, pela inestimável contribuição ao trabalho e à minha formação.

Ao Artur, por servir de exemplo do que é possível atingir quando se leva educação à sério.

À Poli Júnior, por me mostrar que o desejo de se desenvolver pode ser força maior que qualquer ambição material.

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

E a todos os que estão aqui “to put a dent in the universe”.



*“Life can be much broader once you discover one simple fact: everything around you that you call ‘life’ was made up by people that were no smarter than you. And you can change it, you can influence it... Once you learn that, you'll never be the same again”*

*- Steve Jobs*



## RESUMO

O presente trabalho objetiva apresentar um plano completo de ações tomadas para ganho de escalabilidade e melhoria operacional na área de Prevenção à Lavagem de Dinheiro (PLD) em uma *fintech* brasileira em plena expansão, bem como os resultados obtidos. A melhoria operacional na área de PLD da empresa poderia contribuir para a mitigação do risco regulatório ao qual a instituição está imposta, além de reduzir retrabalho e poupar recursos humanos e financeiros nas investigações de possíveis suspeitos de lavagem de dinheiro. A Prevenção à Lavagem de Dinheiro vem ganhando cada vez mais notoriedade no espaço político-econômico brasileiro, e se trata de uma prática relativamente recente. A Lei nº 9613 foi aprovada em 1998, e atribuiu maiores responsabilidades a pessoas físicas e jurídicas na identificação de clientes e atividades suspeitas de lavagem de dinheiro, sujeitando-as a penalidades administrativas pelo descumprimento das obrigações. O plano de melhoria operacional desenvolvido envolveu a exploração de duas principais frentes: (i) aumento da precisão dos alertas de identificação de casos suspeitos de lavagem de dinheiro, e (ii) aumento de produtividade dos analistas de PLD. A elaboração e execução do plano envolveu não somente o exercício de práticas de gestão, mas também a criação de ferramentas e o aprimoramento de análises e monitoramentos empregando *big data*. Após a implementação dos planos de ação, foi possível obter um ganho de cerca de 12 p.p. na taxa de precisão dos alertas de suspeitos de lavagem de dinheiro, e um aumento de cerca de 80% no número de casos analisados por analista em cada dia - resultados considerados positivos dado a proposta inicial das ações planejadas.

**Palavras-chave:** Prevenção à Lavagem de Dinheiro. Metodologias Ágeis. Governança de dados. Aprendizado de Máquina.



## ABSTRACT

This work aims to present a plan to increase actions to increase the scalability and operational efficiency in the AML (Anti-Money-Laundering) operation in a fast-growing Brazilian *Fintech*, as well as show the results that were achieved. The increase in operational efficiency in the AML operations could help mitigate the regulatory risk which the financial institution is subject to, as well as reduce redundant work and save human and financial resources on the investigation of money laundering suspects. AML has been gaining awareness on the Brazilian political and economic spheres, and it may be considered a recent initiative. The “Law 9613” was approved in 1998, and attributed greater responsibilities to the people and companies who were suspect of being involved in money-laundering activities, and established clear penalties, fines and attitudes to be taken should the involvement be verified. The plan to increase operation efficiency involved exploring two distinct objectives: (i) to increase the accuracy of the AML alarms in use, and (ii) To improve the productivity of the AML analysts. The elaboration and execution of the plan involved not only management practices, but also the creation of new tools and the improvement on analyses and monitoring practices using *big data*. After the implementation of the action plans, it was possible to verify a 12 p.p. increase on the AML alerts’ accuracy rate, and an 80% increase on the daily number of cases investigated by each AML analysts – results considered positive given the initial proposition of the actions planned.

**Keywords:** Anti-Money Laundering. Agile Methodology. Data Governance. Machine Learning.





## LISTA DE FIGURAS

Figura 1 - Organograma do time de trabalho do Autor .....	32
Figura 2 - Estrutura do Trabalho de Formatura .....	36
Figura 3 - Esquema de relações entre órgãos reguladores no Sistema Financeiro .....	41
Figura 4 - Esquema ilustrativo sobre o funcionamento da metodologia Scrum.....	45
Figura 5 - Diagrama de um processo de “ETL” convencional.....	48
Figura 6 - Exemplo de um fluxograma de processo modelado em BPMN.....	53
Figura 7 - Diagrama de Ishikawa .....	54
Figura 8 - Matriz de Impacto X Esforço.....	56
Figura 9 – Lógica da taxa de conversão de casos para reportes ao Coaf .....	61
Figura 10 - Organização da Defense Tribe.....	65
Figura 11 - Pseudo-código do alerta de pré-pagamento .....	71
Figura 12 – Processo de Comunicação de Operação Suspeita (COS).....	73
Figura 13 - Diagrama de Causa e Efeito para o Problema 1 .....	76
Figura 14 - Diagrama de Causa e Efeito para o Problema 2 .....	77
Figura 15 - Diagrama de Causa e Efeito para o Problema 3 .....	79
Figura 16 - Matriz de Impacto X Esforço para as soluções propostas .....	85
Figura 17 - Gráfico de Gantt com o planejamento do projeto.....	90
Figura 18 - Sistema de trabalho em Shields .....	104
Figura 19 - Diagrama com lógica do serviço de backoffice.....	107
Figura 20 - Mock-up ilustrativo da tela do serviço .....	108
Figura 21 - Fluxograma de avaliação do Quality Assessment em BPMN .....	113

## LISTA DE QUADROS

Quadro 1 – Regras de identificação de suspeitos com cartão de crédito .....	69
Quadro 2 - Regras de identificação de suspeitos com conta de pagamentos .....	70
Quadro 3 - Problemas identificados no squad de PLD .....	75
Quadro 4 - Propostas de soluções para as causas-raízes do Problema 1.....	82
Quadro 5 - Propostas de soluções para as causas-raízes do Problema 2.....	83
Quadro 6 – Propostas de soluções para as causas-raízes do Problema 3.....	84
Quadro 7 - Quadro-resumo dos OKRs definidos.....	87
Quadro 8 - Mapa de nível de gravidade.....	96
Quadro 9 - Mapa de Probabilidade de ocorrência.....	96
Quadro 10 - Mapa de Probabilidade de ocorrência.....	98
Quadro 11 – Escala de avaliação dos reportes pelo Coaf .....	109
Quadro 12 - Escala de avaliação da etapa de KYC.....	111
Quadro 13 - Escala de avaliação da etapa de Abertura de Tratativa.....	112
Quadro 14 - Escala de avaliação da etapa de Abertura de Tratativa.....	112
Quadro 15 – Afirmções de avaliação do formulário de engajamento.....	115
Quadro 16 – Resumo das iniciativas de engajamento dos analistas de PLD .....	119
Quadro 17 - Resumo do plano de ação para o squad de PLD.....	120

## LISTA DE GRÁFICOS

Gráfico 1 – Evolução da receita e margem da <i>Fintech X</i> nos últimos anos.....	26
Gráfico 2 – Evolução no número de clientes da empresa.....	27
Gráfico 3 - Quantidade de RIFs produzidos por ano.....	40
Gráfico 4 - Quantidade de comunicações e pessoas relacionadas nos RIFs por ano .....	40
Gráfico 5 - Número de casos analisados, tratativas e reportes ao longo do tempo .....	62
Gráfico 6 - Taxas de conversão agregada de casos para reportes ao longo do tempo e nota média de devolutiva do Coaf por reporte .....	63
Gráfico 7 - Número de casos analisados por tipo de alerta de Jan-2018 a Out-2018.....	64
Gráfico 8 - Taxas de conversão para tratativas no alerta de pré-pagamento.....	97
Gráfico 9 - Ranqueamento SHAP de features .....	101
Gráfico 10 – Curva ROC para o modelo implementado .....	102
Gráfico 11 - Média de avaliações por categoria do Formulário de Engajamento .....	116
Gráfico 12 - Evolução da taxa de conversão de casos para reportes.....	122
Gráfico 13 - Taxa de conversão Machine learning vs. Alarmes mínimos .....	123
Gráfico 14 - Evolução no número de casos analisados por analista por dia .....	124
Gráfico 15 - Nota média mensal do reporte enviados ao Coaf.....	125
Gráfico 16 - Nota de engajamento dos analistas de PLD .....	126



## LISTA DE ABREVIATURAS E SIGLAS

AML	<i>Anti-Money Laundering</i>
BACEN	Banco Central do Brasil
BPMN	<i>Business Process Model and Notation</i>
COA	Comunicações de Operações Automáticas
COAF	Conselho de Controle de Atividades Financeiras
COS	Comunicações de Operações Suspeitas
ETL	<i>Extract, Transform, Load</i>
GAFI	Grupo de Ação Financeira
IF	Instituição Financeira
KYC	<i>Know Your Customer</i>
OKR	<i>Objectives and Key Results</i>
PLD	Prevenção à Lavagem de Dinheiro
RBA	<i>Risk-Based Approach</i>
RIF	Relatório de Inteligência Financeira
SQL	<i>Structured Query Language</i>
TI	Tecnologia da Informação
UIF	Unidade de Inteligência Financeira



## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>25</b>
1.1	A Empresa e Definição do Problema .....	25
1.1.1	Cartão de crédito.....	27
1.1.2	Conta de pagamentos.....	28
1.1.3	Programa de recompensas .....	29
1.1.4	Empréstimo pessoal.....	29
1.2	Motivação e Importância do Trabalho.....	30
1.3	Papel do Autor no desenvolvimento do Trabalho .....	31
1.4	Objetivo e escopo .....	33
1.5	Organização do trabalho.....	34
<b>2</b>	<b>REVISÃO BIBLIOGRÁFICA .....</b>	<b>37</b>
2.1	Prevenção à Lavagem de Dinheiro e Financiamento ao Terrorismo (PLD/FT)....	37
2.1.1	Definição .....	37
2.1.2	Histórico da Lavagem de Dinheiro no Brasil .....	38
2.1.3	Coaf .....	39
2.1.4	Regulamentação das instituições financeiras .....	40
2.2	Lean Startup.....	42
2.3	Gestão ágil .....	43
2.3.1	O Manifesto Ágil .....	43
2.3.2	Scrum.....	44
2.3.3	Objective Key Results .....	46
2.4	Governança de dados e informação.....	47
2.5	<i>Machine learning</i> .....	49
2.5.1	Regressão logística .....	49
2.6	Gerenciamento por Processos.....	51
2.6.1	BPMN (Business Process Model and Notation).....	51
2.7	Procedimento de Resolução de Problemas .....	53
2.7.1	Diagrama de Causa e Efeito .....	54
2.7.2	Matriz de Impacto X Esforço .....	55
<b>3</b>	<b>DIAGNÓSTICOS .....</b>	<b>59</b>
3.1	Método.....	59

3.2	Dados de produtividade .....	60
3.3	Análise do time de PLD da empresa .....	64
3.3.1	Modo de operação atual .....	66
3.3.2	Tecnologia de identificação de suspeitos.....	68
3.3.3	Fluxo de processo de análise.....	71
3.4	Problemas e desafios identificados .....	74
3.5	Identificação das causas raízes.....	75
3.5.1	Problema 1: Baixa conversão de casos para reportes do Coaf.....	75
3.5.2	Problema 2: Número insuficiente de casos analisados por mês.....	77
3.5.3	Problema 3: Notas de qualidade insatisfatória dos reportes realizados .....	79
3.6	Levantamento de soluções .....	81
3.7	Priorização de soluções .....	84
3.8	Definição de OKRs ( <i>Objective Key Results</i> ) .....	85
<b>4</b>	<b>DESENVOLVIMENTO DO TRABALHO .....</b>	<b>89</b>
4.1	Planejamento da implementação.....	89
4.2	Objetivo 1: aumentar a precisão dos alertas de PLD .....	91
4.2.1	Geração de alertas .....	92
4.2.2	Tecnologias a serem utilizadas .....	93
4.2.3	Detalhamento da solução .....	94
4.3	Objetivo 2: aumentar a produtividade dos analistas de PLD .....	103
4.3.1	Detalhamento da solução .....	104
4.4	Resumo do Plano .....	119
<b>5</b>	<b>RESULTADOS E DISCUSSÃO .....</b>	<b>121</b>
5.1	Análise dos resultados obtidos.....	121
5.2	Impactos organizacionais.....	127
5.3	Benefícios conjunturais ao Sistema Financeiro Nacional.....	128
<b>6</b>	<b>CONCLUSÕES .....</b>	<b>129</b>
<b>7</b>	<b>REFERÊNCIAS BIBLIOGRÁFICAS.....</b>	<b>131</b>



## 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 Definição do Problema

A empresa onde trabalha o Autor 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.

A *fintech* em questão possui uma série de serviços financeiros já oferecidos ao grande público, e conta com mais de 12 milhões de clientes em sua base. Os principais produtos ofertados são: um cartão de crédito, uma conta de pagamentos, um programa de recompensas, e uma linha de empréstimo pessoal. Ela foi fundada em São Paulo, e possui somente um escritório, na própria cidade. Tendo uma história relativamente recente, ela é tida como umas das pioneiras e referência na revolução do ecossistema de *startups* brasileiras.

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 do Autor na *Fintech X*, e pôde não somente ser planejado com alto grau de cuidado, mas também implementado com a participação ativa do Autor do trabalho.

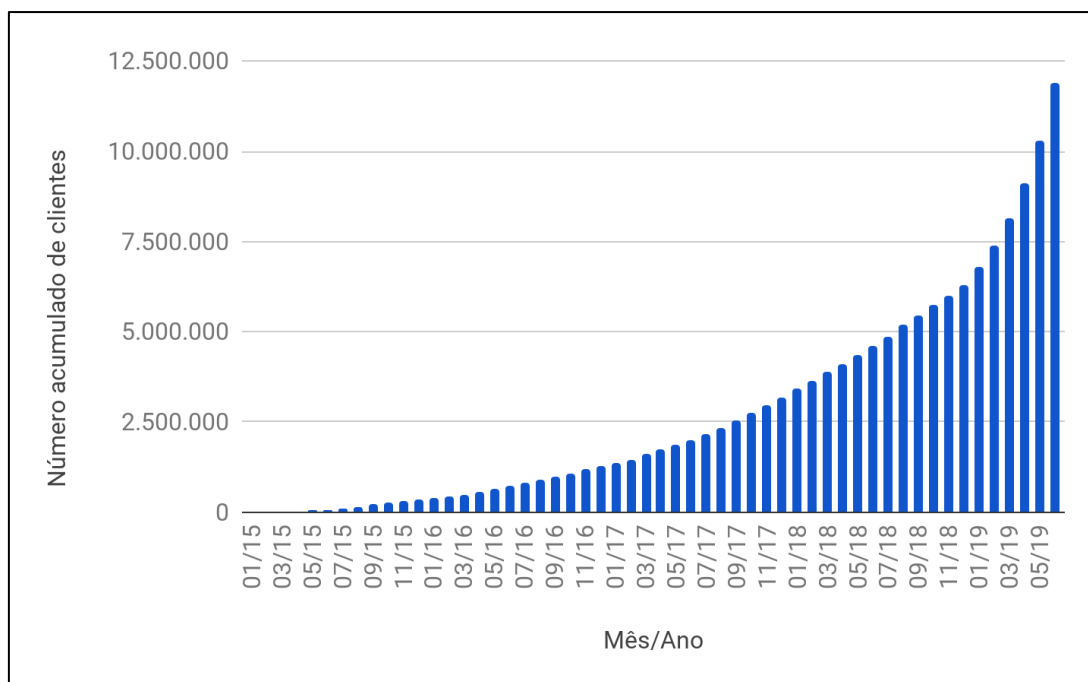
O gráfico a seguir ilustra a evolução da Receita e da Margem Operacional da empresa nos últimos anos - com destaque ao crescimento anual médio da Receita Operacional de aproximadamente 257%, um forte indicador da capacidade de expansão de negócios vista comumente em *startups* neste estágio de vida. Os dados foram modificados por um múltiplo arbitrário por motivos de confidencialidade.

**Gráfico 1 – Evolução da receita e margem da *Fintech X* nos últimos anos**

Fonte: Elaborado pelo Autor

Vale notar também a reversão na Margem Operacional da empresa, que era negativa nos anos de 2015 e 2016, e passou a ser positiva a partir de 2017. Este movimento denota uma perspectiva positiva na trajetória da *Fintech X*, que está amadurecendo seu modelo de negócios e conseguindo deixá-lo sustentável a longo prazo.

O gráfico seguinte ilustra o crescimento exponencial da empresa em sua base de usuários. Os dados foram novamente modificados por um múltiplo arbitrário.

**Gráfico 2 – Evolução no número de clientes da empresa**

Fonte: Elaborado pelo Autor

Como é possível perceber, o cenário de hiper-crescimento pelo qual passa a *Fintech X* implica em 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* foi o primeiro produto de seu portfólio. Trata-se de um cartão físico que tem 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. Ambos os atrativos, embora hoje aparentem ser relativamente comuns no mercado brasileiro, eram considerados uma bem-vinda novidade no setor quando o produto foi lançado, em 2013.

Hoje, o cartão é o principal driver 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, em termos de geração de receita, quanto mais os 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 alicerce 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* foi um produto que surgiu após o lançamento inicial do cartão de crédito, e trata-se de um passo natural na evolução do negócio. O seu principal atrativo é 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, é possível que duas pessoas com contas da *Fintech X* realizem transferências entre si à qualquer hora do dia, sem depender do horário comercial.

Como se pode observar, 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 recompensas

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. Além disso, o usuário do programa pode ter acesso a descontos exclusivos em lojas parceiras da *Fintech X*. 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

Por fim, o último produto lançado no portfólio da empresa foi o 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*.

## 1.2 Motivação e Importância do Trabalho

O Brasil vive atualmente um momento de grande volume de investimento em *startups*. Desde 2011, quando o empreendedorismo digital começou a acelerar no país, foram aportados cerca de R\$13 bilhões em empresas tecnológicas brasileiras. Em 2018, foram investidos cerca de R\$5,1 bilhões, volume 51% superior ao de 2017 - um montante que representou 65% de todos os investimentos feitos na América Latina (ÉPOCA NEGÓCIOS, 2019).

Os expressivos valores de mercado atingidos por essas empresas e o levantamento de grandes volumes de capital de risco destinados às *startups*, conhecido como *venture capital*, é reflexo não somente da quantidade de novas empresas surgindo, mas também da transformação que elas estão provocando em diversos setores. A *Fintech X*, considerada uma das empresas mais proeminentes no setor de *fintechs*, tem como principal proposta trazer disrupção a este concentrado mercado. Estima-se que os 5 maiores bancos do Brasil concentrem mais de 80% dos empréstimos e depósitos feitos em 2018 em todo o país. (UOL ECONOMIA, 2019)

Apesar de haver uma noção generalizada de que *startups* devam crescer e ampliar sua base de usuários de forma extremamente acelerada, nem sempre a operação necessária para dar suporte a esse crescimento é escalada de forma proporcional. Além disso, em uma *startup* de serviços financeiros, setor altamente regulamentado, é necessário que não somente as operações de negócios estejam fluindo de maneira adequada, mas também que os riscos regulatórios estejam sendo continuamente mitigados.

Instituições financeiras, por terem seus negócios centrados precisamente nas movimentações de capital, acabam sendo instrumento de ocultação e passagem de dinheiro oriundo de atividades ilícitas - operação comumente conhecida como "lavagem de dinheiro". Nota-se que o aumento da base de clientes e do uso dos produtos da *Fintech X* naturalmente aumenta o risco de haver movimentações suspeitas passando todos os dias pela empresa. Portanto, torna-se extremamente importante garantir que a operação de investigações de casos suspeitos seja escalável juntamente com o resto das operações da empresa.

A não-conformidade às regulamentações da Lei de Prevenção à Lavagem de Dinheiro (Lei nº 9.613/98) pode acarretar em multas expressivas para a instituição financeira, perda da licença de operação e dano reputacional de grande impacto. Sendo indiscutível a importância de se manter uma operação eficiente e de alta qualidade nas investigações, o desafio do Autor do Trabalho de Formatura foi descobrir o que poderia ser melhorado e também participar da implementação de todo o plano de melhoria.

Vale explicitar a diferença entre aumento de eficiência e ganho de escalabilidade, uma

vez que é possível uma empresa possuir um e não possuir o outro. Wojtczak (2002) define “eficiência” como “a habilidade de se executar bem ou atingir um resultado sem desperdícios de energia, recursos, esforço, dinheiro ou tempo” - uma definição em linha com Drucker (1973), que define “eficiência” como “fazer certo as coisas”, em oposição ao conceito de “eficácia”, que seria “fazer as coisas certas”. Já “escalabilidade” é definida por Bondi (2000) como “a propriedade de um sistema de suportar uma quantidade crescente de trabalho através de acréscimo de recursos ao sistema”.

Logo, nota-se que a busca pela escalabilidade na área de PLD de uma *startup* como a *Fintech X* consiste no desenvolvimento de sistemas e mecanismos que assegurem uma operação suave de investigações mesmo com o crescimento exponencial na base de usuários da empresa, enquanto a busca pela eficiência consiste em realizar melhorias na operação de forma a buscar resultados cada vez melhores, com cada vez menos desperdícios de tempo e recursos.

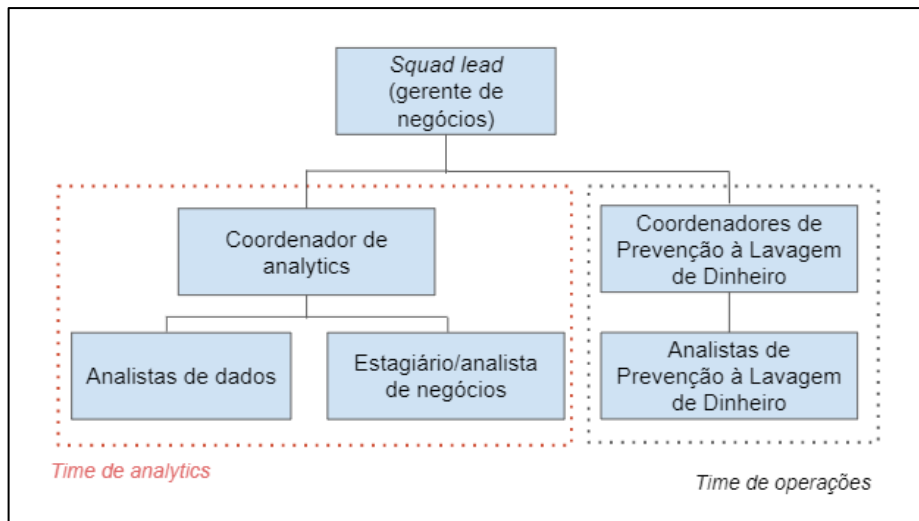
Trata-se, como é possível ver, de um projeto pouco usual no contexto de outros Trabalhos de Formatura relacionados a *startups*. Enquanto empresas deste porte e natureza costumam estar majoritariamente focadas em expansão agressiva através de aquisição de clientes e escalabilidade de operações de atendimento, além de desenvolvimento de novos produtos, o fato de a *Fintech X* atuar em um setor altamente regulamentado traz consigo este interessante desafio a ser resolvido, e de extrema importância não somente para a própria companhia, mas também no combate ao crime organizado em esfera nacional.

### **1.3 Papel do Autor no desenvolvimento do Trabalho**

O Autor do Trabalho de Formatura participou ativamente no processo de redesenho operacional da área e na criação de ferramentas que alavancaram a eficiência dos analistas de Prevenção à Lavagem de Dinheiro. Logo no início do estágio na *Fintech X* em Agosto de 2018, o Autor foi alocado na área com o objetivo de trazer melhorias tangíveis na operação de PLD, como estagiário de análise de negócios.

O organograma a seguir ilustra a configuração do time no momento em que o Autor iniciou seu estágio.

**Figura 1 - Organograma do time de trabalho do Autor**



Fonte: Elaborado pelo Autor

Pode-se notar uma divisão de funções clara dentro do organograma. O Time de Operações, composto por 9 analistas e 2 coordenadores de PLD, possui um conhecimento de Prevenção à Lavagem de Dinheiro mais especializado, e é encarregado de realizar efetivamente as investigações que a *Fintech X* precisa cumprir para estar de acordo com as regulamentações às quais está sujeita.

Já o time de *Analytics*, no qual o Autor foi alocado, é basicamente composto por um coordenador de *analytics*, e três pessoas que dividiam as tarefas de estruturação e análise de bases de dados para a tomada de decisões estratégicas da área, sendo dois analistas de dados. A função do Autor está descrita como "Estagiário/analista de negócios" porque embora tenha atuado como estagiário, o escopo do trabalho exercido na equipe é exatamente igual ao de um analista.

Vale notar que essa configuração multifuncional, com times de *analytics* atuando como suporte para as equipes de operação, 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 rotação de trabalho. O cerne de suas funções é justamente saber extrair e manipular dados e modelos para tomar decisões bem-fundamentadas nas mais diversas áreas de negócio.

O Autor do Trabalho de Formatura desenvolveu uma série de ferramentas e análises que serão melhor apresentadas ao longo do trabalho, e como é comum em empresas de crescimento acelerado, teve de desempenhar tarefas que às vezes fugiam-lhe do seu escopo original. Essas tarefas, que envolveram aspectos de gerenciamento da operação - incluindo redesenho de



processos e monitoramento dos índices de qualidade das investigações dos analistas de PLD - se provaram ser momentos de grande aprendizado ao Autor. Como também é comum em *startups*, foi necessário que o Autor aprendesse ferramentas das mais diversas, escolhendo a que fosse mais adequada para cada problema de negócio. O Autor trabalhou de forma intensa com as linguagens de programação Scala, Python e SQL, realizando análises na plataforma integrada à arquitetura de *big data* da empresa, e os softwares MS Excel e MS PowerPoint, bem como outros softwares de gestão como o Trello, Airtable e Slack.

Por meio da realização do estágio na empresa em questão, o Autor do Trabalho de Formatura pôde aplicar e aprofundar diversos conhecimentos adquiridos ao longo do curso de Engenharia de Produção. Tópicos aprendidos em disciplinas como Estatística e Gestão da Tecnologia da Informação foram de grande importância na execução do plano de melhoria na precisão dos alertas de PLD, e temas em Gestão de Operações em Serviços, Organização do Trabalho e Projeto Integrado de Sistemas de Produção foram de especial relevância para a execução do plano de aumento de produtividade dos analistas de PLD.

A estruturação de times de Prevenção à Lavagem de Dinheiro que atuam de forma ágil ainda pode ser considerada incipiente no Brasil, e o Autor deste Trabalho espera que o mesmo possa contribuir para que empresas no país sigam melhores práticas e utilizem tecnologias cada vez mais avançadas para que os crimes financeiros e o financiamento ao terrorismo no Brasil sejam combatidos com ainda mais inteligência. Este resultado traria benefícios sistêmicos que seriam usufruídos por todos os brasileiros.

#### **1.4 Objetivo e escopo**

O objetivo do Trabalho de Formatura consiste em apresentar todo o desenvolvimento das ferramentas e iniciativas de ganho de escalabilidade e eficiência elaborados pelo Autor e sua equipe no *squad* de PLD, e mostrar o resultado gerado por essas iniciativas. De forma geral, os projetos desenvolvidos podem ser divididos em duas frentes, com objetivos distintos:

- (i) Aumentar a precisão dos alertas de PLD
- (ii) Aumentar a produtividade dos analistas de PLD

O primeiro projeto surgiu da necessidade de se melhorar os índices de precisão dos alertas de PLD internos da empresa, que se encontravam aquém do desejado. Um alerta é basicamente um conjunto de regras que indica atividade suspeita de lavagem de dinheiro. Há uma série de

alertas na área - cada um deles cobrindo atividades e produtos da empresa diferentes - mas o líder da área identificou ineficiências na identificação de risco proveniente destes alertas, que serão melhor detalhadas no capítulo “3.4 Problemas e desafios identificados”. No intuito de reduzir a proporção dos falso-positivos (os chamados corriqueiramente de "alarmes falsos"), o Autor foi encarregado de elaborar uma estratégia para resolver esse problema e implementá-la.

Já o segundo projeto surgiu da hipótese de que os analistas de PLD não estavam analisando um número de casos suficiente por dia, já que não conseguiam atingir as metas já relativamente modestas que lhes eram atribuídas. Nota-se que este objetivo complementa o primeiro objetivo: era necessário não somente entregar casos de maior risco aos analistas, mas também garantir que eles conseguissem analisá-los a uma taxa de produtividade saudável para a *Fintech X*, de modo que o risco regulatório estivesse sendo mitigado ao máximo.

É mister situar as ações realizadas no contexto da gestão ágil. Fitzgerald et al (2013) afirma ser perfeitamente possível aplicar métodos ágeis em ambientes altamente regulados, ao aliar desenvolvimento rápido de software e entregáveis tangíveis seguindo a metodologia Scrum, com uma resposta rápida à mitigação de risco e aderência a protocolos e regulamentações. Ao final, no capítulo “5. Resultados e Discussão”, será possível ver o impacto das medidas realizadas para a organização como um todo.

Faz-se necessária uma importante observação: o termo “*squad*”, 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. 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 PLD, 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 dividido em seis capítulos diferentes.

O primeiro capítulo consiste na introdução, já apresentada.

O segundo capítulo se refere à Revisão Bibliográfica, que traz o referencial teórico e o arcabouço acadêmico dos conceitos de Engenharia de Produção apresentados ao longo do Trabalho. Serão explorados temas que foram relevantes não somente à elaboração do Diagnóstico dos desafios da *Fintech X*, mas também ao Desenvolvimento do projeto, o que

resultou em ações concretas para a empresa que puderam ser embasadas por conceitos estudados pelo Autor ao longo do curso de Engenharia de Produção.

O terceiro capítulo se refere 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 em sua área de PLD, incluindo uma análise de como os processos são realizados atualmente e os problemas e desafios que foram encontrados ao longo do processo.

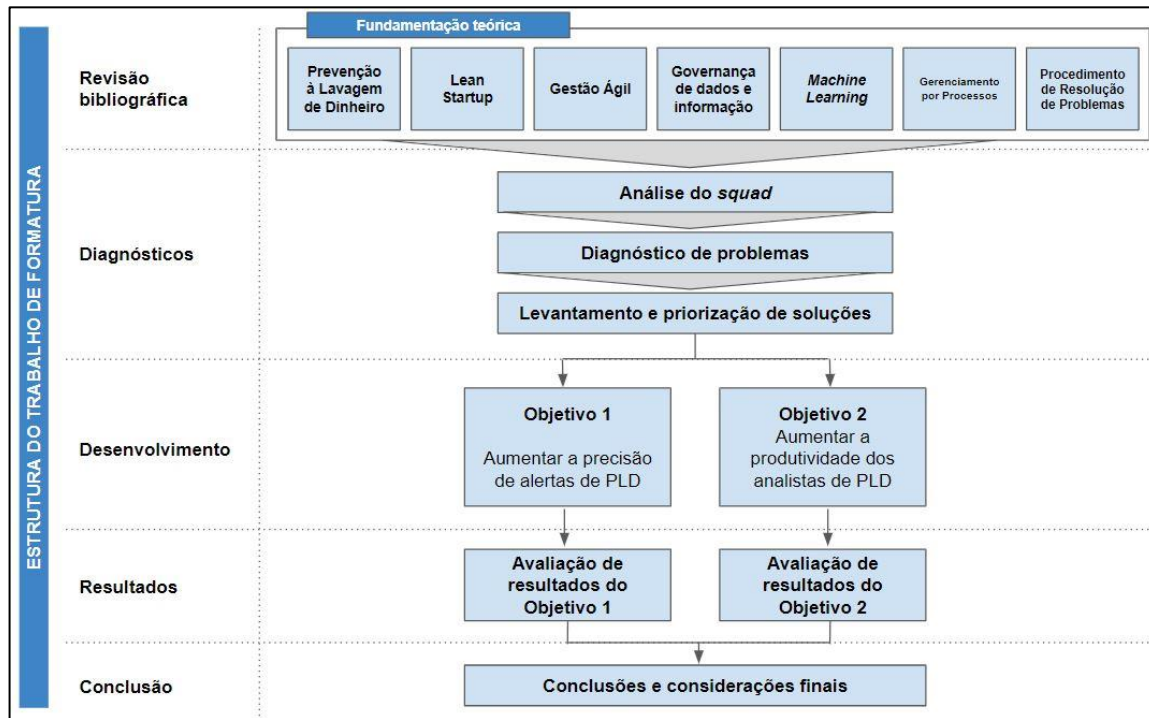
O quarto capítulo envolve o Desenvolvimento do Trabalho, no qual são especificados os planos de ação que foram elaborados pelo Autor do TF em conjunto com sua equipe, e como eles foram postos em prática. Trata-se da execução dos planos que foram criados para resolver os problemas identificados no capítulo de Diagnóstico.

O quinto capítulo consiste na apresentação dos Resultados e a Discussão deles. Durante o período de estágio o Autor e sua equipe tiveram tempo hábil de não somente planejar e executar os planos, mas também observar os resultados das mudanças implementadas. Portanto será possível observar e analisar dados e informações relevantes de como a área foi impactada pelas medidas.

Por fim, há um capítulo de Conclusão, no qual o Autor apresenta as considerações finais acerca do Trabalho e o aprendizado obtido.

O esquema a seguir ilustra como está organizada a lógica do Trabalho de Formatura.

**Figura 2 - Estrutura do Trabalho de Formatura**



Fonte: Elaborado pelo Autor

## 2 REVISÃO BIBLIOGRÁFICA

Neste capítulo, será feita a revisão de literatura sobre conceitos e métodos de resolução relacionados ao cumprimento do objetivo descrito no capítulo anterior, a fim de embasar o método desenvolvido neste estudo.

Os tópicos abordados serão:

- Prevenção à Lavagem de Dinheiro e Financiamento ao Terrorismo (PLD/FT);
- *Lean Startup*;
- Gestão ágil.
- Governança de dados e informação;
- *Machine learning*;
- Gerenciamento por Processos;
- Procedimento de Resolução de Problemas

### 2.1 Prevenção à Lavagem de Dinheiro e Financiamento ao Terrorismo (PLD/FT)

#### 2.1.1 Definição

A lavagem de dinheiro se caracteriza como uma operação financeira ou comercial que deseja incorporar capital de origem ilícita na economia de um país, de modo a transformá-lo no lucro de um bem, produto ou serviço lícito. A transgressão pode ter como objetivo ocultar a receita de atos ilícitos praticados, ou também alavancar a realização de crimes futuros de qualquer tipo e gravidade (RAMOS, 2016).

Atribui-se a origem do termo Money Laundering (em português, "lavagem de dinheiro") à prática do gângster americano Al Capone, na década de 1920, de utilizar uma rede de lavanderias para ocultar a origem do lucro obtido com a venda de bebidas alcoólicas nos Estados Unidos na época da Lei Seca (RAMOS, 2016).

Segundo Neves (2003), para a consumação da lavagem de dinheiro, na atualidade, as instituições financeiras são um dos setores da economia mais visados pelos criminosos. Isto porque, por conta das características de seu negócio, há a disponibilidade de uma série de produtos e serviços que, associados à utilização de novas tecnologias, permitem a circulação e ocultamento de recursos com grande velocidade. Através de transações financeiras, o dinheiro de origem ilícita se mistura a valores movimentados legalmente, favorecendo o processo de

dissimulação da origem espúria.

Dentre os organismos internacionais destinados a combater este tipo de prática, de acordo com Neves (2003), pode-se destacar o GAFI - Grupo de Ação Financeira Internacional. O órgão é responsável por desenvolver e promover políticas ao redor do mundo para combater a lavagem de dinheiro, e também atua como uma espécie de órgão fiscalizador, avaliando as medidas tomadas pelos países para combater e prevenir esta operação. Ele foi fundado em 1989 por uma iniciativa dos países do G-7, e reúne os países da OCDE e outros que possuem grande importância regional, como Índia, China e Brasil.

### **2.1.2 Histórico da Lavagem de Dinheiro no Brasil**

No Brasil, o crime de lavagem de dinheiro foi tipificado na Lei 9.613 de 03.03.1998 - que foi posteriormente alterada pelas Leis 10.467 de 11.06.2002, e 20.701 de 09.07.2003 - definindo-o no artigo primeiro como:

*"Ocultar ou dissimular a natureza, origem, localização, disposição, movimentação ou propriedade de bens, direitos ou valores provenientes, direta ou indiretamente, de crime:*

*I - de tráfico ilícito de substâncias entorpecentes ou drogas afins;*

*II - de terrorismo e seu financiamento; (Redação dada pela Lei n° 10.701, de 09.07.2003)*

*III - de contrabando ou tráfico de armas, munições ou material destinado à sua produção;*

*IV - de extorsão mediante seqüestro;*

*V - contra a Administração Pública, inclusive a exigência, para si ou para outrem, direta ou indiretamente, de qualquer vantagem, como condição ou preço para a prática ou omissão de atos administrativos;*

*VI - contra o sistema financeiro nacional;*

*VII - praticado por organização criminosa;*

*VIII - praticado por particular contra a administração pública estrangeira.*

*(Inciso incluído pela Lei n° 10.467, de 11.06.2002)"*

A Lei tornou crime a conduta de ocultar ou dissimular a origem de bens produtos do crime, e conforme o Brasil havia se comprometido a fazer pela Convenção de Viena, trouxe um outro avanço importante, que foi a criação de uma Unidade de Inteligência Financeira nacional, que foi chamada de Conselho de Controle de Atividades Financeiras - o Coaf.

Em linhas gerais, o Banco Central (BACEN) trabalha para que o Sistema Financeiro Nacional (SFN) não seja utilizado para fins ilícitos, sendo parte do plenário do Coaf, e é representado por 1 dentre os 11 Conselheiros. Cabe ao BACEN o papel de regulamentar, monitorar e fiscalizar o SFN de modo a garantir que instituições financeiras bancárias e não bancárias implementem procedimentos e controles de PLD/FT. O Coaf, por sua vez, centraliza as informações e reportes referentes a atividades suspeitas, sendo considerado uma unidade de inteligência financeira.


### **2.1.3 Coaf**

O Coaf começou a funcionar em 1999, um ano após a criação da Lei da Lavagem de Dinheiro. Seguindo as recomendações internacionais, ele é um órgão central, único no país, encarregado de receber informações sobre operações e movimentações de dinheiros suspeitas, analisar essas informações, e encaminhar os casos onde realmente existam indícios de prática de crime para a polícia e para o Ministério Público. Ele também troca informações com Unidades de Inteligência Financeira de outros países.


Vale ressaltar que a Unidade de Inteligência Financeira não possui responsabilidade investigativa. De acordo com Neves (2003), ela apenas se limita a analisar informações que possui e encaminhar as que são de fato relevantes para os órgãos competentes que realizam a investigação, comunicando às Autoridades quando conclui pela existência de indícios de crime.

Os resultados do trabalho de recebimento e análise das comunicações de operações suspeitas de lavagem de dinheiro proveniente dos setores exigidos são documentados na forma de Relatórios de Inteligência Financeira (RIF). Estes relatórios agrupam diversas comunicações de operações financeiras de pessoas físicas e jurídicas que são enviadas pelas Instituições Financeiras.

Os gráficos a seguir ilustram a quantidade de RIFs produzidos por ano e a quantidade de comunicações e de pessoas relacionadas nos RIFs por ano.

**Gráfico 3 - Quantidade de RIFs produzidos por ano**

Fonte: Relatório de atividades do Coaf de 2018

**Gráfico 4 - Quantidade de comunicações e pessoas relacionadas nos RIFs por ano**

Fonte: Relatório de atividades do Coaf de 2018

Os relatórios elaborados são então encaminhados às Autoridades competentes em diferentes Unidades da Federação e no exterior, para que tomem as medidas cabíveis.

#### 2.1.4 Regulamentação das instituições financeiras

As Instituições Financeiras (IFs) são orientadas a enviar informações de atividades suspeitas ao Coaf, porém são regulamentadas pelo BACEN, que é o responsável final em





## 2.2 Lean Startup

A empresa-foco do Trabalho de Formatura é comumente retratada na mídia como uma *startup*. Este termo é empregado de diversas formas por Autores diferentes. Ries (2011) define uma *startup* como "uma organização humana criada para desenvolver um novo produto ou serviço em condições de extrema incerteza". Nesta definição, o termo "incerteza" se reveste de especial importância - as *startups*, especialmente quando estão em sua infância, geralmente passam por ciclos iterativos de desenvolvimento de produto e validação de modelos de negócios que fogem do padrão já estabelecido no mercado em que atuam. Isto torna a previsão de sucesso de um negócio deste tipo uma tarefa árdua.

Para Graham (2009), *startups* são organizações desenhadas para o rápido crescimento, e geralmente de base tecnológica. É comum, portanto, que desde a sua concepção, elas se apoiem sobre tecnologias e plataformas recentes, e utilizem o potencial dessas ferramentas para transformar um segmento de mercado que não se aproveitava delas. Ainda segundo Graham (2009), o melhor indicador que pode ser usado para medir a taxa de crescimento de uma *startup* é a evolução da receita. ou em caso de *startups* que ainda não possuem um modelo de receita sustentável, o crescimento no número de usuários ativos. Estas métricas são acompanhadas de perto até hoje pela *Fintech X*, mesmo passados 6 anos após sua concepção.

Ries (2011) afirma que o empreendedorismo necessita de gestão. Essa ideia pode ser contrária a de muitos empreendedores que acreditam que aplicar técnicas de gestão podem aumentar a burocracia e minimizar a criatividade, levando muitos a adotarem a prática de evitar qualquer tipo de gestão ou disciplina. No entanto, essa atitude acaba por gerar caos e ameaça o sucesso das *startups*.

O sistema proposto por Ries (2011) é derivado das técnicas de produção enxuta de Taiichi Ohno e Shigeo Shingo. Dentre as características da produção enxuta que inspiraram o método, Ries (2011) destaca:

- Produção just in time
- Aceleração do tempo de ciclo
- Valorização do conhecimento e criatividade dos trabalhadores
- Diminuição dos tamanhos dos lotes
- Reconhecimento das tarefas criadoras de valor e do desperdício

Seguindo as técnicas de aprendizado científico, busca-se minimizar o risco e o desperdício através do teste das hipóteses de negócio, escalando-o apenas quando se tem testado e validado. (RIES, 2011)

A metodologia *Lean Startup* possibilita que a empresa iniciante faça ajustes necessários a partir do processo de *feedback* Construir-Medir-Aprender. Com os resultados, é possível entender se é necessário seguir o caminho ou então mudar de curso (pivotar, na linguagem do *Lean Startup*), até que se encontre o modelo correto para ser escalado em forma de uma companhia. Segundo Ries (2011), o objetivo de uma *startup* é a de criar um negócio sustentável e replicável e essa deve ser a visão que guia o empreendimento. Para atingir a visão é necessária uma estratégia, ou seja, um modelo de negócios. A implementação dessa estratégia geralmente se dá por meio de um produto, desenvolvido por meio de processos iterativos seguindo o ciclo citado anteriormente.

## **2.3 Gestão ágil**

A gestão ágil de desenvolvimento de software é um termo guarda-chuva para uma série de métodos e práticas baseados nos valores expressos pela primeira vez no chamado no Manifesto Ágil, em 2001. Ela inclui soluções que evoluem a partir da colaboração entre equipes auto-organizadas e multidisciplinares que utilizam as práticas apropriadas para esse contexto.

### **2.3.1 O Manifesto Ágil**

O termo “ágil” foi aplicado a essa coleção de metodologias de gestão em 2001 quando 17 desenvolvedores se uniram para discutir ideias e diferentes abordagens para o desenvolvimento de software. Essa coleção de valores e princípios foi expressa no Manifesto Ágil (Manifesto for Agile Software Development) (AGILE ALLIANCE, 2001). A proposta tem como enfoque uma lista de valores que foram levantados, debatidos e acordados entre todos os presentes e representam a base que guia e une todas as metodologias ditas ágeis.

O primeiro valor diz respeito ao favorecimento dos indivíduos e das interações sobre os processos e as ferramentas. Cockburn (2002), um dos que elaboraram o manifesto, afirma que este valor prega o hábito de tratar pessoas como membros de uma equipe e não como cargos em um diagrama de processos. Abrahamsson et al (2002) levanta o ponto de que as

metodologias ágeis favorecem relacionamentos mais intensos entre pequenos times como forma de estimular as interações e o espírito de equipe.

O segundo valor presente no manifesto é o de favorecer software que esteja funcionando ao invés de uma documentação extensa. Este valor se justifica pelo fato de que apenas o funcionamento do sistema ilustra o que a equipe construiu, enquanto que a documentação é uma maneira de se construir imagens futuras de próximos estágios de desenvolvimento (Cockburn, 2002). Segundo Abrahamsson et al (2002) a questão da documentação tem sua prioridade diminuída frente ao constante esforço que a equipe deve exercer para manter o software testado e funcional.

O terceiro valor prega a colaboração com o cliente frente à negociação em contratos. Cockburn (2002) ilustra este valor dizendo que no desenvolvimento ágil não há a distinção entre quem desenvolve o software e quem o requisitou, e sim apenas uma ou mais empresas presentes num esforço integrado para a implementação da solução de um problema. Abrahamsson et al (2002) atenta para o fato de que ainda assim um contrato passa a ganhar mais importância frente à colaboração com o cliente conforme o tamanho do sistema cresce.

O último valor se refere a dar mais importância para a resposta à uma mudança do que seguir algum plano. Cockburn (2002) cita que as metodologias ágeis aceitam alterações de prioridades entre ciclos de desenvolvimentos que normalmente tem apenas entre duas e quatro semanas. Estes ciclos curtos permitem a construção de um software funcional ao mesmo tempo em que favorece a mudança de prioridades por parte dos patrocinadores do projeto.

Fitzgerald et al (2013), complementa a discussão sobre desenvolvimento ágil ao estudar sua aplicação em ambientes altamente regulamentados. Ele afirma que os maiores conflitos esperados pela aplicação do agile nesses ambientes, tais como falta de planejamento formal e mitigação de risco da metodologia, falta de atenção à documentação e preferência a software “bom o suficiente” e não “perfeito” podem ser resolvidos através de um sistema robusto de validação contínua para checagem da qualidade do que é entregue, priorização de mitigação de risco por ordem de gravidade, e resposta rápida a mudanças estruturais no ambiente regulatório.

### **2.3.2 Scrum**

Segundo Highsmith e Cockburn (2001), o que há de novo sobre métodos ágeis não são as práticas que eles usam, mas o reconhecimento de que as pessoas são o principal motor e responsáveis para o sucesso dos projetos, combinado com um foco intenso em eficácia e

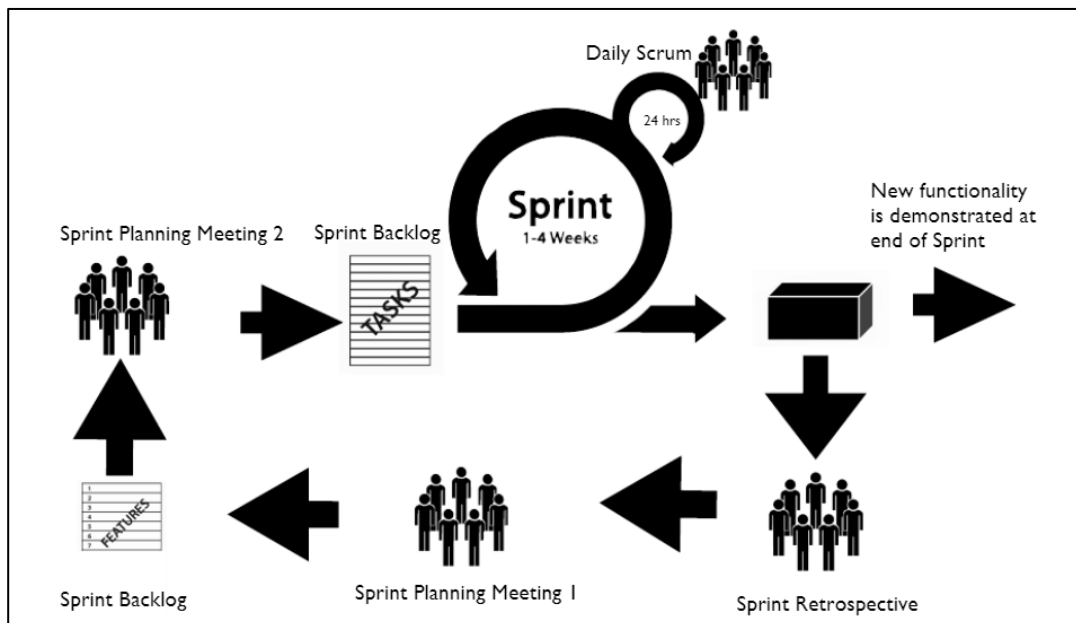
manobrabilidade, ou seja capacidade rápida de mudança. Isso culmina em uma nova combinação de valores e princípios que definem uma visão de mundo ágil.

Uma das abordagens para o desenvolvimento ágil de software é o Scrum. Segundo Jeff Sutherland (2011), o desenvolvedor do Scrum, o objetivo do método é entregar o máximo possível de software de qualidade dentro de pequenas janelas de tempo chamadas *sprints*.

A abordagem do Scrum foi desenvolvida para gerenciar o processo de desenvolvimento de sistemas. É uma abordagem empírica que aplica ideias de teoria de controle para o desenvolvimento de sistemas, resultando em uma abordagem que reintroduz as ideias de flexibilidade, adaptabilidade e produtividade (SCHWABER; BEEDLE, 2002). Este método não especifica parâmetros técnicos do produto, apenas sugere práticas gerenciais, ferramentas e cerimônias (ABRAHAMSSON et al., 2002).

O Scrum começa no *backlog* do produto, uma lista com todos os requisitos de projeto (ABRAHAMSSON et al, 2002). Uma lista de *features* ou atividades técnicas que são suficientes para completar o projeto ou um release, a próxima versão. Antes de cada *sprint*, há uma *sprint planning*. Nessa cerimônia, a equipe decide os itens de *backlog* de produto que irão priorizar na próxima *sprint* e o plano inicial para completá-los (AGILE ALLIANCE, 2018).

**Figura 4 - Esquema ilustrativo sobre o funcionamento da metodologia Scrum**



Fonte: Jeff Sutherland's Scrum Handbook (2010)

Durante a *sprint*, todos os dias, no mesmo horário, ocorre a “daily”. Essa reunião tem um prazo curto pré-determinado, em geral 15 minutos (AGILE ALLIANCE, 2018). Cada membro da equipe expõe o que já concluiu desde a última *daily* e o que pretende concluir até a próxima. Os impedimentos encontrados para o desenvolvimento também são brevemente discutidos (ABRAHAMSSON, et al, 2002)

Ao fim da *Sprint*, há duas reuniões, a *review* e a retrospectiva. Na reunião de *review*, a equipe apresenta os resultados e incrementos no produto para o líder do projeto, os clientes e as demais partes interessadas. A partir desses resultados, são tomadas decisões para as próximas *sprints*, podendo inclusive aparecer novos itens de *backlog* (ABRAHAMSSON et al, 2002).

A retrospectiva, ou “retro”, não precisa necessariamente ser no último dia de toda *Sprint*. Essa reunião ocorre de forma periódica para que os membros da equipe possam refletir sobre acontecimentos importantes desde a última retro, tanto no sentido do desenvolvimento do produto quanto na relação entre os membros da equipe (AGILE ALLIANCE, 2018).

### 2.3.3 Objective Key Results

A metodologia de OKRs foi elaborada na década de 80 por Andy Grove, que trabalhava para a Intel, e popularizada por John Doerr na década de 90. Ela ganhou notoriedade por ser abertamente utilizada pelo Google, desde a época em que a empresa possuía cerca de 40 funcionários, até os dias atuais. (DOERR, 2018)

Após alcançar sucesso no Google, a ferramenta passou a ser utilizada por diversas outras *startups* e empresas de tecnologia, como LinkedIn, Twitter e Uber, e é geralmente utilizada juntamente com outros princípios de gestão ágil dessas empresas, mesmo que ela não tenha sido concebida originalmente no Manifesto Ágil. (DOERR, 2018)

Os OKRs, como o nome sugere, são compostos por objetivos bem-definidos acompanhados de resultados-chave, ou seja, métricas que podem ser utilizadas para acompanhar o cumprimento daquele objetivo. A principal proposta da metodologia é definir como se atingir objetivos dentro de uma organização através de ações que são concretas, específicas e de resultados mensuráveis - características que trazem mais clareza ao conceito de “metas” e aumentam o engajamento do funcionário com as tarefas que devem ser feitas. Os resultados-chave podem ser medidos por meio de uma escala de 0-100% ou por qualquer outra unidade numérica. (DOERR, 2018)

## 2.4 Governança de dados e informação

O principal diferencial tecnológico adotado pela *Fintech X* em seus primeiros anos não se trata de um único software disruptivo, ou um hardware inovador, mas sim o uso de dados em larga escala para tomar decisões estratégicas da empresa.

Segundo Koltay (2016), a governança de dados ou de informação contempla todas as entidades organizacionais, práticas, políticas, padrões, tomadas de decisão, responsabilidades e métodos com relação aos dados. Desta maneira, a adoção da governança de dados ou de informação pode contribuir para a diminuição de conflitos operacionais, reduzir custos, aumentar a efetividade através da coordenação dos esforços e permitir a transparência dos processos (KOLTAY, 2016).

Sob a perspectiva estratégica, dados de boa qualidade podem ser considerados condição fundamental para que as organizações enfrentem os desafios de negócio e os objetivos empresariais, e do ponto de vista operacional, os processos organizacionais dependem da existência de dados de alta qualidade (WEBER et al, 2009). A noção cada vez mais disseminada de dado como um "ativo organizacional" tem levado diversas organizações - desde as *startups* até empresas mais tradicionais - a repensarem sua abordagem de tratamento das informações, principalmente considerando a necessidade que possuem de reportarem situações de forma correta, precisa e confiável (KHATRI; BROWN, 2010).

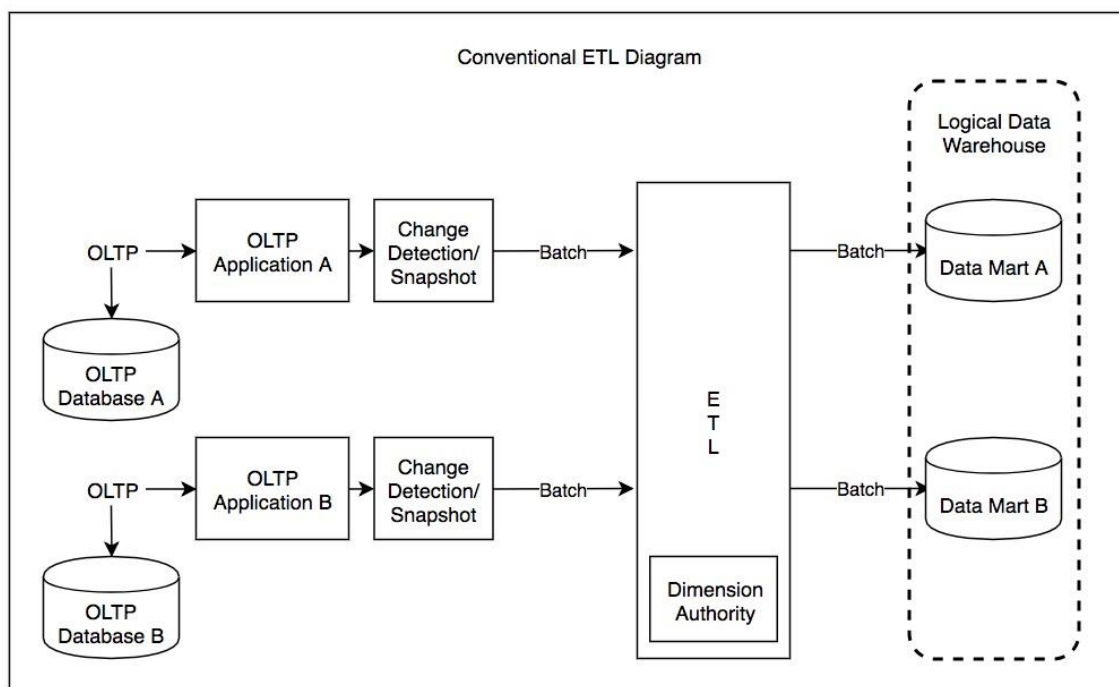
Segundo Kimball (2002), um dos ativos mais importantes de uma organização é a sua informação. Esse ativo normalmente é armazenado de duas maneiras em uma organização: em sistemas transacionais e no *data warehouse* (DW). O Autor propõe uma analogia para exemplificar esses diferentes papéis: os usuários do sistema transacional ou de operações da organização são aqueles que fazem a roda girar, enquanto que os usuários do *data warehouse* observam a roda girar.

Apesar da existência de diversas definições, opiniões e conceitos sobre o que seria *data warehouse*, Machado (2006) ressalta a importância de perceber que não existe um modelo de *data warehouse* pronto para ser utilizado. É necessário um trabalho de levantamento de necessidades da organização e de seus executivos, de modo a permitir a elaboração de um projeto de *data warehouse* que esteja alinhado com o direcionamento da empresa e de seus comandantes.

O ambiente de DW começa com o processo de *Extract, Transform and Load* (ETL). Os dados são extraídos das bases de dados transacionais, transformadas para atender aos padrões do *data warehouse*, e por fim são carregados, tanto na base única do DW, na abordagem de

Inmon, ou então nas diversas pequenas bases de dados, conhecidas como *data marts*, propostas por Kimball. O processo de ETL é essencial para a viabilidade do *data warehouse*, pois este é o responsável por garantir a integridade dos dados dentro do DW. Os sistemas transacionais e legados não são desenhados para produzirem resultados compatíveis entre si, o que torna a tarefa de integrar os dados no DW extremamente trabalhoso, sendo algumas vezes considerada mais intensiva do que as próprias atividades de análise de suporte à decisão. O diagrama a seguir ilustra o processo de funcionamento convencional da ETL proposto por Kimball.

**Figura 5 - Diagrama de um processo de “ETL” convencional**



Fonte: KIMBALL, R., (2004)

Neste contexto, o declínio constante de custos de praticamente todos os elementos de computação - armazenamento, processamento, memória e banda de comunicação - tem trazido viabilidade econômica para abordagens intensivas em dados (MCAFEE e BRYNJOLFSSON, 2012). Em linhas gerais, o que diferencia *Big Data* de outras tecnologias de extração e análise de informações para obtenção de vantagens competitivas são três fatores: volume, velocidade e variedade (MCAFEE e BRYNJOLFSSON, 2012). Esta tríade também é conhecida como "3V's", e é de fundamental importância para que o real valor do *Big Data* seja efetivamente constatado.



## 2.5 *Machine learning*

Subcampo da inteligência artificial, o aprendizado de máquina (ou *Machine learning*, em inglês) é a área que engloba o estudo e a construção de sistemas inteligentes a partir de dados (MOHRI, ROSTAMIZADEH e TALWALKAR, 2012). Tais sistemas passam por uma fase denominada "treinamento", ou "aprendizado", em que recebem dados existentes como input para assimilar padrões, e depois esses sistemas podem ser utilizados para classificar ou estimar saídas para instâncias desconhecidas.

Witten e Frank (2005) descreveram quatro conceitos caracterizando os vários algoritmos de aprendizado de máquina: aprendizado por classificação, no qual um conjunto de exemplos pertencentes às classes são utilizados para construir modelos; aprendizado por associação, no qual o objetivo é identificar grupos de um ou mais atributos que determinam o valor de classe de uma instância; aprendizado por agrupamento, no qual exemplos semelhantes de acordo com um critério estabelecido são agrupados; e aprendizado por regressão, cujo objetivo é desenvolver um modelo matemático correlacionando atributos com o valor de classe.

### 2.5.1 Regressão logística

A regressão logística é um tipo de modelo de classificação probabilístico que visa estimar o valor de classe de uma variável dependente a partir de outras variáveis discretas e/ou contínuas (HOSMER e LEMESHOW, 2005). A classe que se deseja estimar (chamada de variável-alvo) é frequentemente binária - caso existam mais de duas classes, deve ser usada a chamada regressão logística multinomial.

As variáveis independentes podem ser do tipo reais, binárias ou categóricas. Elas podem ser classificadas como contínuas, como por exemplo, idade, renda e peso, ou discretas, como gênero ou tipo sanguíneo. As variáveis discretas expressas na forma de texto podem ser codificadas numericamente em categorias ou em atributos binários adicionais.

Para que possa ser estimada a probabilidade de cada observação pertencer a uma ou outra classe, a variável resposta do conjunto de treinamento é modelada por meio da distribuição binomial, que tem como parâmetro  $p$  a probabilidade de ocorrência de uma classe específica. Vale notar que esta probabilidade deve estar limitada ao intervalo  $[0,1]$  e apresentar relação direta com os preditores mensurados para cada observação do conjunto de dados (KUHN; JOHNSON, 2013).

Para a estimação da probabilidade  $p$ , utiliza-se a função logística:

$$p(X) = \Pr(Y = k | X = x) = \frac{\exp(\beta_0 + \sum_{j=1}^p \beta_j X_j)}{1 + \exp(\beta_0 + \sum_{j=1}^p \beta_j X_j)}$$

O ajuste do modelo logístico pode ser realizado a partir da aplicação do método da máxima verossimilhança, que estima valores para o vetor de parâmetros. As estimativas corresponderão àquelas que resultam nas probabilidades preditas para cada observação do conjunto de treinamento mais próximas da verdadeira classe à qual a observação pertence (JAMES et al., 2014). A função de verossimilhança formaliza matematicamente o método:

$$L(\beta) = \prod_{i=1}^n (p(X)^{y_i} (1 - p(X))^{1-y_i})$$

de modo que as estimativas do vetor serão escolhidas a fim de maximizar a função acima. Por fim, o vetor de parâmetros estimados será utilizado para prever a resposta de interesse em novas observações (JAMES et al., 2014). Detalhes mais profundos sobre o método da máxima verossimilhança e sobre características inferenciais do modelo logístico podem ser encontrados em Agresti (2013) e em Hosmer, Lemeshow e Sturdivant (2013).

No caso de uma resposta binária, em que o resultado seja 0 ou 1, se  $p(X)$  é a probabilidade associada à presença de determinada resposta, a chance  $p/(1-p)$  desse desfecho ocorrer será:

$$\frac{\Pr(Y = 1 | X = x)}{\Pr(Y = 0 | X = x)} = \frac{p(X)}{1 - p(X)} = \exp(\beta_0 + \sum_{j=1}^p \beta_j X_j)$$

A fronteira de decisão linear do modelo de regressão logística estará relacionada à escolha de um ponto de corte para  $p(X)$ . Por exemplo, se o ponto de corte escolhido for  $p(X) = 0,5$ , indivíduos com  $p(X) > 0,5$  serão classificados como um evento (presença de determinada resposta, por exemplo, o valor 1 em problemas de respostas dicotômicas) e aqueles com  $p(X) < 0,5$  como um não evento (ausência de determinada resposta, ou o valor 0 no caso citado).

Logo,  $p(X) = 0,5$  irá definir a fronteira de decisão linear para tal modelo, cujo log da chance, nesse caso, será zero (JAMES et al., 2014).

## 2.6 Gerenciamento por Processos

Gonçalves (2000) diz que processos são atividades agrupadas para adicionar valor a inputs de uma organização, a fim de gerar uma saída que atenda a seus clientes. Um processo de negócio é também o trabalho que gerencia ou oferece suporte para outros processos em uma organização (PROFESSIONALS, 2013). Abdala (2006) ressalta que tais atividades são provenientes de diferentes áreas da empresa, as quais são interdependentes e, portanto, devem ser bem conhecidas e mapeadas.

A gestão por processos tem sido uma alternativa buscada por empresas motivadas pela necessidade de serem competitivas e com foco em seus clientes (SMART; MADDERN; MAULL, 2009). Seethamraju et al. apud Damian; Borges e Pádua (2015) dizem que o engajamento dos profissionais e o desempenho de uma organização estão relacionados à medida em que seus processos estão alinhados e bem definidos.

A referida gestão é conhecida como *Business Process Management* (BPM), planejando, executando, avaliando e corrigindo processos a fim de melhorar a performance organizacional (PROFESSIONALS, 2013; TRKMAN, 2010). Uma de suas características é a capacidade de relacionar as necessidades do cliente com as atividades da empresa, traduzindo tal relação em processos que sejam efetivos para os dois lados (SMART; MADDERN; MAULL, 2009).

Uma empresa deve buscar a melhoria contínua de seus processos de forma proativa, e não somente esperando eventos que chamem a atenção para a ineficiência de um processo. Além disso, a atenção deve ser redobrada nos processos críticos à empresa, os quais variam para cada organização. As ferramentas de análise devem considerar aspectos humanos, tecnológicos e estratégicos. A mudança proposta pode ser radical ou gradual; ainda que seja disruptiva, porém, deverá ser seguida por melhorias incrementais (PROFESSIONALS, 2013).

Para a análise de um processo, Professionals (2013) cita alguns fatores críticos de sucesso e recomendações a serem observadas, como a criação de um documento que mostra o atual processo e por que deveria sofrer mudanças, a listagem de propostas de solução (mas sem desenvolvê-las durante esse estágio de análise), a alocação correta de recursos relativos ao processo em questão, o foco no ponto de vista do cliente e a atenção à cultura da empresa.

### 2.6.1 BPMN (Business Process Model and Notation)

Pode-se definir "notação" como "conjunto padronizado de símbolos e regras que

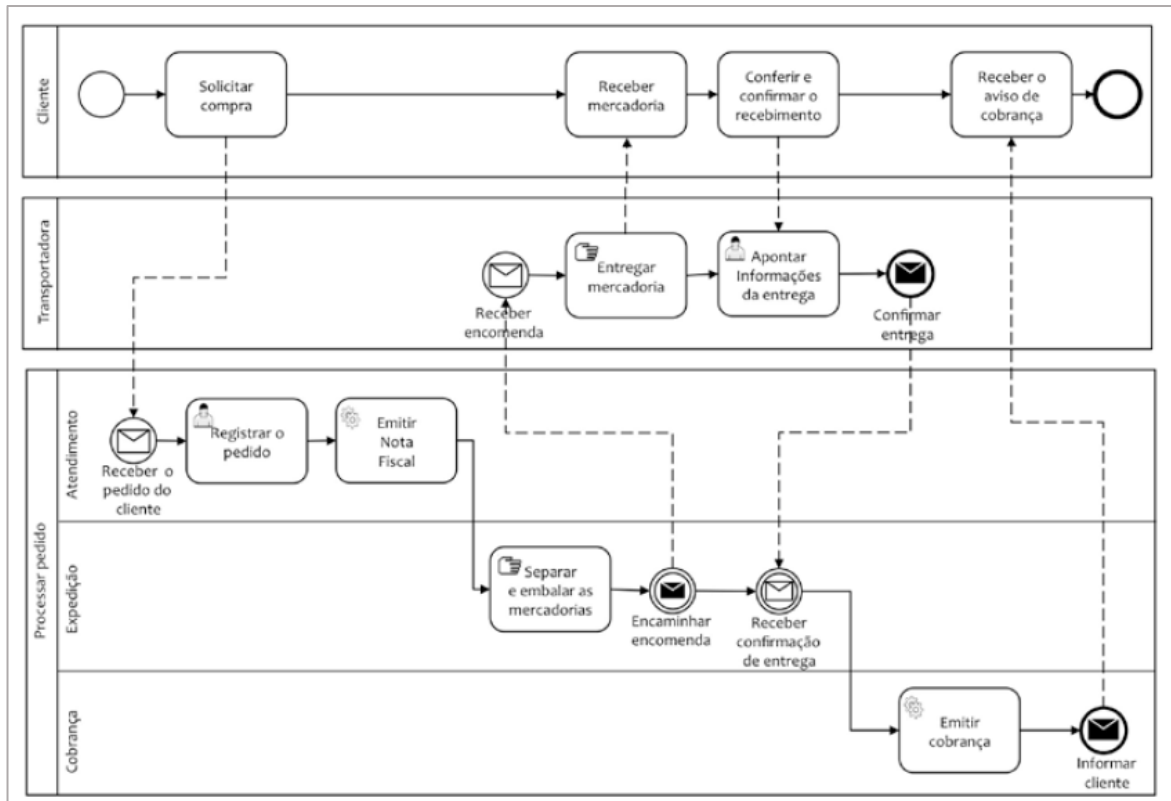
determinam o significado desses símbolos" (ABPMP, 2013, p.77). Dentre as notações mais comuns no mercado, há a BPMN (*Business Process Model and Notation*) criada pela BPMI (Business Process Management Initiative) e incorporada ao OMG (Object Management Group). Esse padrão tem um conjunto robusto de símbolos para a modelagem de diferentes aspectos de processos de negócio. Como na maioria das notações, os símbolos descrevem relacionamentos claramente definidos, tais como o fluxo de atividades e ordem de precedência (ABPMP, 2013).

Em BPMN, raias dividem um modelo em várias linhas paralelas. Cada uma dessas raias é definida como um papel desempenhado por um ator na realização do trabalho. O trabalho se move de atividade para atividade seguindo o caminho do fluxo de papel a papel. A forma como os modelos em BPMN são elaborados deve ser guiada por padrões corporativos, caso a visão de longo prazo seja a construção de um modelo integrado de negócio da organização. Esses padrões devem reger quando e como as raias são definidas, como as atividades são decompostas, quais dados são coletados na modelagem, entre outros (ABPMP, 2013).

O BPMN é recomendado quando é necessário apresentar um mapa ou modelo de processos para públicos-alvo diferentes ou quando temos de simular um processo de negócio com um motor de processo. Como vantagens, o BPMN apresenta uso e entendimento difundido em muitas organizações, e versatilidade para modelar as diversas situações de um processo. Como principais desvantagens, BPMN exige treinamento e experiência para uso correto do conjunto completo de símbolos, dificulta a visualização do relacionamento entre vários níveis de um processo (quando há muitos) e diferentes ferramentas podem ser necessárias para apoiar diferentes subconjuntos da notação.

O presente trabalho concentra-se em utilizar o BPMN em sua visão em raias (ABPMP, 2013).

**Figura 6 - Exemplo de um fluxograma de processo modelado em BPMN**



Fonte: ABPMP CBOK V3.0 (2013)

## 2.7 Procedimento de Resolução de Problemas

Segundo Hitoshi Kume (1993), “Um problema é o resultado indesejável de um trabalho”. Solucionar um problema é mudar o resultado de um patamar indesejado para um razoável. Além disso, Kume (1993) sugere que um problema pode ser resolvido ao se seguir as sete etapas descritas a seguir:

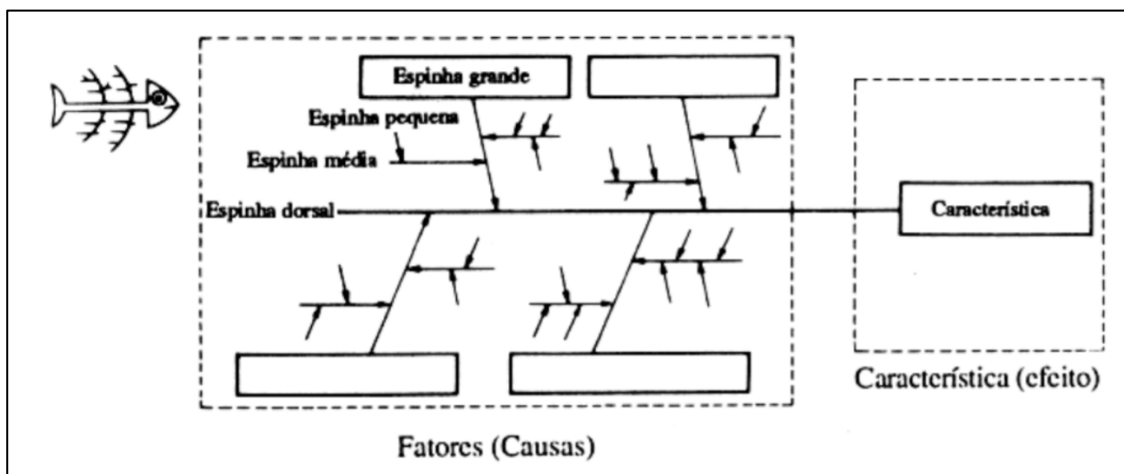
1. **Problema:** Identificação do problema
2. **Observação:** Reconhecimento dos aspectos do problema
3. **Análise:** Descoberta das principais causas
4. **Ação:** Ação para eliminar as causas
5. **Verificação:** Verificação da eficácia da ação
6. **Padronização:** Eliminação definitiva das causas
7. **Conclusão:** Revisão das atividades e planejamento para o trabalho futuro

Kume (1993) chega a prescrever em detalhe as ferramentas de controle de qualidade e procedimentos mais adequados para cada etapa da resolução de um problema, bem como o encadeamento entre elas. Neste Trabalho, serão descritas em maior profundidade duas ferramentas: O Diagrama de Causa e Efeito e a Matriz de Esforço vs. Impacto.

### 2.7.1 Diagrama de Causa e Efeito

Para a etapa de análise de problemas, Kume (1993) recomenda estabelecer hipóteses e testá-las. Sugere-se o uso do diagrama de causa e efeito para o levantamento de hipóteses, uma ferramenta que contém as questões relacionadas aos diferentes aspectos do problema, e também conhecido como Diagrama de Espinha de Peixe ou Diagrama de Ishikawa. O seu valor provém do fato de relacionar características da qualidade com possíveis fatores de causa, em diferentes níveis de detalhe.

**Figura 7 - Diagrama de Ishikawa**



Fonte: Kume (1993)

É comum que se utilize uma configuração do diagrama conhecida como 6M, com fatores pré-estabelecidos para cada uma das espinhas grandes (DALE; VAN DER WIELE; VAN IWAARDEN, 2007). Os fatores são:

1. Método;
2. Mão de obra;

3. Meio Ambiente;
4. Matéria Prima;
5. Medidas;
6. Máquinas.


É possível realizar o levantamento das causas dentro de cada fator através do aproveitamento das informações da fase de observação e da realização de *brainstormings* (KUME, 1993). Segundo Dale, Van der Wiele e Van Iwaarden (2007), *brainstorming* é um método de expressão livre empregado para a dedução de soluções de problemas e o levantamento de ideias criativas. A dinâmica pode ser feita tanto de forma estruturada ou desestruturada e funciona melhor em grupos de pessoas, embora também possa ser feita individualmente.

### **2.7.2 Matriz de Impacto X Esforço**

A Matriz de Impacto e Esforço tem como objetivo definir, a partir de um conjunto de soluções e critérios pré-estabelecidos, quantas e quais soluções devem ser implementadas, avaliando cada uma delas em relação ao esforço requerido de implementação e impacto na área ou organização. (ANDERSEN, FAGERHAUG e BELTZ, 2010)

No eixo X coloca-se o esforço necessário para se implementar a solução em uma escala de três níveis (baixo, médio e alto), e no eixo Y, o impacto esperado pela implementação, também em uma escala de três níveis. A figura a seguir ilustra o modelo da matriz utilizada no Trabalho.

**Figura 8 - Matriz de Impacto X Esforço**



Fonte: Andersen, Fagerhaus e Beltz (2010)

Os quadrantes denotam projetos com denominações e características específicas, explicadas a seguir:

- *Fill-in jobs*: Soluções facilmente implementadas, porém de retorno limitado. Valeriam a pena somente se houver recursos e tempo sobrando devido à ausência de projetos com retorno maior.
- *Hard slogs*: Soluções que dificilmente deveriam ser implementadas devido ao alto esforço necessário e baixo impacto resultante.
- *Quick-wins*: Projetos de ganho rápido e considerável e baixo esforço. Geralmente os primeiros a serem implementados caso a unidade organizacional deseje retornos rápidos.
- *Major projects*: Soluções de alto impacto, porém que requerem alto esforço. Devem ser cuidadosamente considerados e exigem grande planejamento prévio.

Uma vez definida a matriz, cabe a cada equipe definir sua própria estratégia de priorização de projetos. Deve-se ressaltar, entretanto, que há controvérsias sobre este método de priorização. O método perde eficácia devido à baixa qualidade das estimativas de esforço e



impacto, uma vez que são dimensões de caráter mais qualitativo, e que são dificilmente mensuráveis. (GILAD, 2017).



### 3 DIAGNÓSTICOS

Este capítulo tem como objetivo apresentar um diagnóstico preliminar dos desafios encontrados no *squad* de PLD da *Fintech X*. Estes desafios motivaram o Autor e a equipe de *analytics* da área a implementar melhorias que serão descritas em maior detalhe no capítulo seguinte.

#### 3.1 Método

A escolha do tema, descrito neste Trabalho de Formatura, consistiu em identificar quais eram os problemas mais relevantes que justificassem a realização do trabalho e a colaboração da organização. Diferentemente de casos em que os problemas da área ou organização se encontram ocultos, e é necessário realizar um trabalho de descoberta desses problemas, no *squad* de PLD os desafios a serem superados se encontravam relativamente claros. Isto porque a performance do *squad* era medida por métricas bastante objetivas, e tais métricas se encontravam aquém do esperado.

Desta maneira, o método de resolução de problemas empregado neste projeto parte do pressuposto que as métricas de produtividade do *squad* deveriam ser aprimoradas, e foi empregado grande esforço na sistemática de resolução desses problemas a partir deste ponto.

A forma mais eficaz de atingir os objetivos é basear a resolução do problema em dados e informações (KUME, 1993). Portanto, foi necessário levantar informações sobre a forma como funcionava a estrutura e a operação do *squad* de PLD, sendo cobertas todas as etapas do trabalho dos analistas, desde a geração automatizada dos alertas até a decisão pelo reporte ao Coaf ou não-prosseguimento da investigação. Esta etapa foi importante para que fosse compreendido objetivamente o estado atual da operação, ainda sem qualquer julgamento ou proposta de modificação.

Em seguida, com uma visão mais aprofundada da estrutura e operação do *squad*, foram levantadas as hipóteses sobre as causas raízes de cada problema por meio de um diagrama de causa e efeito. Identificadas as causas raízes, para cada uma delas foram associadas propostas de solução por meio de um *brainstorming* em equipe, e o levantamento de sugestões de solução mencionadas pelos stakeholders ao longo do desenvolvimento do trabalho.

A fim de considerar os prós e contras dessas propostas, cada uma delas foi avaliada por meio de uma matriz de impacto X esforço. Por fim, uma vez selecionadas as melhores propostas, elas foram implementadas, e seus resultados foram acompanhados.

Vale notar que, devido a uma combinação de cultura organizacional ágil e apetite da equipe por projetos de rápida implementação, a etapa de identificação de causas-raízes e priorização de propostas ocorreu de forma rápida, em cerca de duas semanas. O intuito era que houvesse mais tempo para implementar uma primeira versão de cada solução, ainda que não completamente madura, para iterar em cima delas e realizar melhorias ao longo do caminho. A etapa de implementação de todas as soluções durou cerca de três meses.

A sistemática adotada pode parecer ortodoxa para uma *startup*, que costumam usar metodologias mais modernas para a resolução de problemas, como o chamado *design thinking*. Entretanto, por se tratar de um desafio ligado à operação interna da empresa, e pelo fato de o Autor do Trabalho de Formatura e o coordenador de *analytics* terem *background* em Engenharia de Produção, a escolha de uma sistemática já consolidada de resolução de problemas pareceu natural.

### 3.2 Dados de produtividade

Existem algumas métricas-chave que são acompanhadas de perto pela *squad* de PLD. São elas:

- (i) número de casos analisados por mês;
- (ii) média de qualidade das análises realizadas;
- (iii) porcentagem de conversão de casos para tratativas;
- (iv) porcentagem de conversão de tratativas para reportes ao COAF.

Nota-se que as métricas (i) e (ii) são de responsabilidade do time de operações, uma vez que, com processos bem estruturados e eficiência nas investigações, torna-se uma tarefa bastante voltada à própria operação da área maximizar o número de alertas analisados por mês e garantir que elas estejam sendo realizadas segundo elevado padrão de qualidade.

Por outro lado, as métricas (iii) e (iv) podem ser consideradas responsabilidade direta do time de *analytics*, uma vez que é seu trabalho garantir que os casos que estão sendo entregues à operação possuam elevado grau de risco de lavagem de dinheiro.

A conversão de um caso para uma tratativa ocorre quando o analista faz uma investigação preliminar do caso alertado, comprova que existe risco de lavagem de dinheiro, e decide abrir uma via de comunicação com o cliente. Esta comunicação sempre se dá por e-mail, e consiste em uma simples requisição de comprovante de renda, para que o cliente comprove que possui capacidade financeira alta o suficiente para justificar as condições de disparo do alerta (que geralmente exige valores expressivos de transações ou movimentações). Dessa maneira, uma alta taxa de conversão de casos para tratativas indica que os casos que estão sendo analisados possuem um risco considerável de lavagem de dinheiro. Na comunicação, o cliente não deve ser informado que está sendo investigado.

Já a conversão de tratativas para reportes ao Coaf ocorre somente nos casos em que o cliente se recusa a mandar informações quando requisitado, ou envia informações que corroboram para a sua suspeita. Estes casos são considerados os mais suspeitos possíveis, e a *Fintech X* deve cumprir sua obrigação regulatória de reportá-los ao Coaf.

A relação entre as variáveis acima pode ser exemplificada pela lógica abaixo:

**Figura 9 – Lógica da taxa de conversão de casos para reportes ao Coaf**

*Taxa de conversão  
agregada de casos  
para reports*

$$r = n * \overbrace{c_1 * c_2}$$

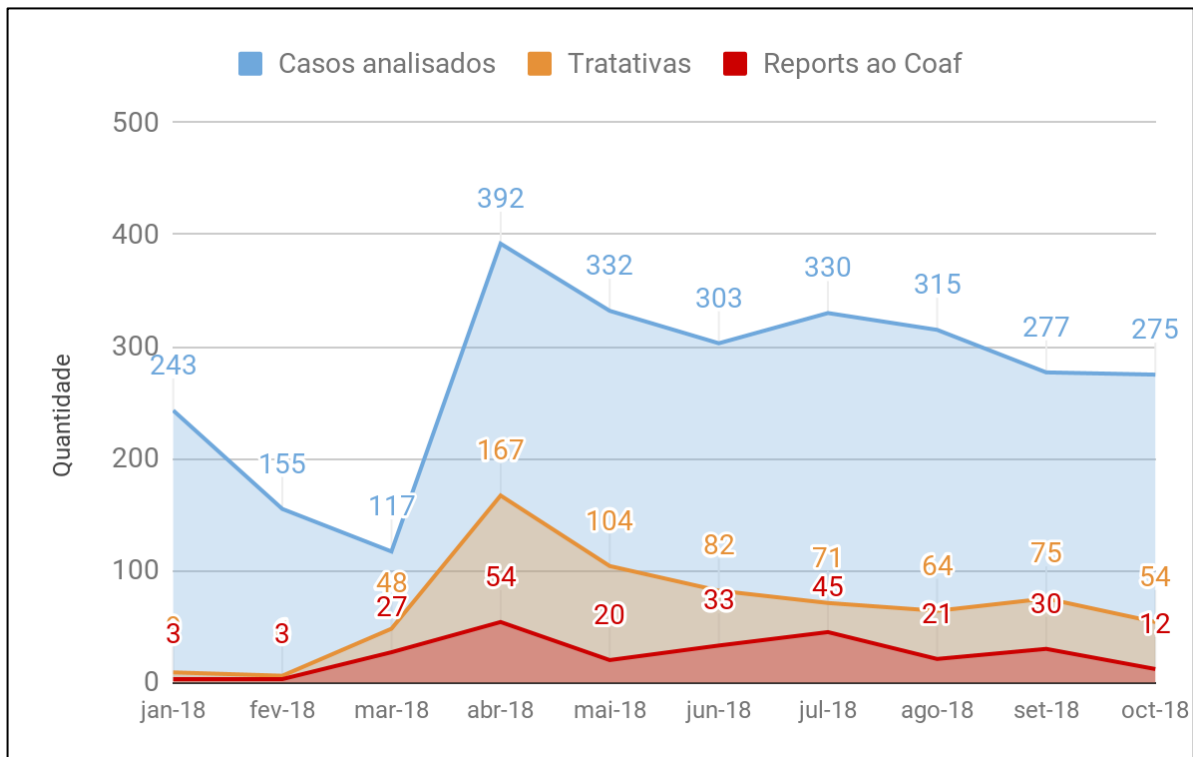
*r* = número de *reports* ao Coaf  
*n* = número de casos a serem analisados  
*c*<sub>1</sub> = taxa de conversão de casos para tratativas  
*c*<sub>2</sub> = taxa de conversão de tratativas para reportes

Fonte: Elaborado pelo Autor

Para questões de simplificação, o time de *analytics* adotou que a métrica de “Taxa de conversão agregada de casos para reportes” seria a principal métrica de risco a ser monitorada, uma vez que, naturalmente, casos de alto risco teriam uma conversão alta para tratativas, e de tratativas para reportes ao Coaf.

O gráfico a seguir mostra a evolução no número de casos analisados pelo *squad*, o número de tratativas abertas, e o número de reportes enviados ao Coaf. Os números deste gráfico, bem como de todos os demais contendo informações internas à *Fintech X* foram alterados por múltiplos arbitrários por motivos de confidencialidade.

**Gráfico 5 - Número de casos analisados, tratativas e reportes ao longo do tempo**




Fonte: Elaborado pelo Autor

Nota-se que em Abril de 2018 houve um aumento súbito nas três métricas avaliadas. Isto se deve ao fato de no mês anterior três novos analistas terem sido contratados para integrar o time, que antes possuía seis analistas. Passado o período de treinamento, os novos integrantes do time conseguiram contribuir para um aumento no número de casos analisados. Entretanto, pode-se observar que a tendência nas três métricas ao longo dos meses foi de queda - o que pode ser explicado por um possível “comodismo” com os processos de análise. O Autor do Trabalho de Formatura ingressou na área em Agosto de 2018, ou seja, em meio a este cenário de declínio das métricas.

O gráfico seguinte mostra a evolução das taxas de conversão de casos para reportes ao Coaf, e a nota média atribuída pelo órgão considerando todos os reportes enviados em cada mês.

**Gráfico 6 - Taxas de conversão agregada de casos para reportes ao longo do tempo e nota média de devolutiva do Coaf por reporte**



Fonte: Elaborado pelo Autor


Não é possível observar uma correlação clara entre as duas métricas. O mês de março apresentou um pico de taxa de conversão para reportes; uma hipótese é a de que, com mais analistas chegando e sendo treinados, foram realizados um número maior de tratativas e reportes não exatamente por um aumento no risco dos clientes, mas por propósitos de demonstração dessas operações para os novos analistas. A curva de nota média dos reportes analisados não parece seguir uma lógica concreta - ela apresentou uma elevação no mês de julho, mas que não conseguiu ser sustentada nos meses subsequentes.

Vale ressaltar que as notas atribuídas pelo Coaf por reporte variam de 1 (a pior) a 4 (a melhor), e só são divulgadas após 1 a 2 meses do envio do reporte, e portanto, é realizado um exercício de preenchimento retroativo dessas notas na planilha de controle do *squad*, para que as avaliações recebidas sejam relacionadas ao mês em que os reportes foram efetivamente enviados. As notas são calculadas a partir de uma metodologia não divulgada pelo Coaf, que inclui tanto o grau de risco de lavagem de dinheiro do suspeito contido no reporte, quanto a completude das informações apresentadas.

Por fim, o gráfico a seguir mostra a distribuição de casos analisados por cada alerta existente. A sigla “CC” significa “Cartão de Crédito” - ou seja, dizem respeito a alertas relacionados ao produto de cartão de crédito da *Fintech X*, e “CP” significa “Conta de Pagamentos”, referindo-se a alertas relacionados a este produto. Há uma distribuição bastante desigual entre os alertas porque nem todos oferecem o mesmo risco.

O detalhamento de cada um dos alertas se encontra no capítulo “3.3.2 Tecnologia de identificação de suspeitos”.

**Gráfico 7 - Número de casos analisados por tipo de alerta de Jan-2018 a Out-2018**



Fonte: Elaborado pelo Autor

As próximas seções terão como objetivo realizar um diagnóstico objetivo do funcionamento do *squad* de PLD de modo que o leitor esteja mais familiarizado com o modo de operação do time.

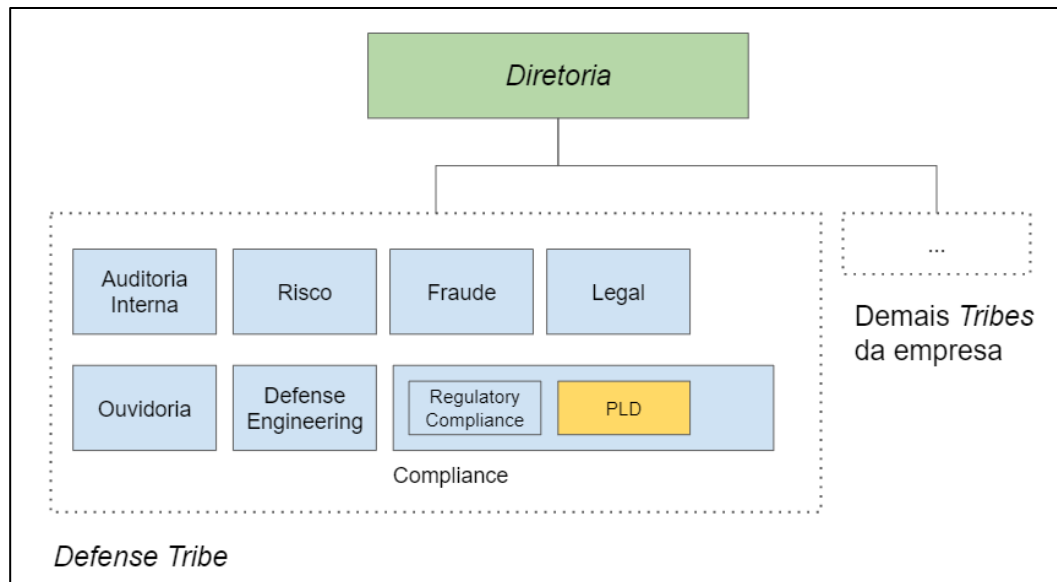
### 3.3 Análise do time de PLD da empresa

O time de PLD da empresa está localizado dentro do *Compliance Squad*, que por sua vez está abaixo da chamada *Defense Tribe*, que reúne todos os *squads* que possuem como objetivo “identificar e monitorar os principais riscos da *Fintech X*, e liderar esforços para mitigá-los”, segundo a definição da própria empresa. A *Defense Tribe* também é composta, além do *squad* de PLD, pelos *squads* de Auditoria Interna, Risco, Fraude, *Legal*, Ouvidoria e *Defense Engineering*.



O diagrama abaixo ilustra como a *Defense Tribe* e, mais especificamente, o *Compliance Squad* se organizam.

**Figura 10 - Organização da *Defense Tribe***



Fonte: Elaborado pelo Autor

O *squad* de PLD, em linhas gerais, é responsável por garantir que a *Fintech X* esteja cumprindo com toda a regulamentação referente à Lei da Prevenção à Lavagem de Dinheiro no Brasil. Isto significa manter controles robustos de detecção dos possíveis lavadores de dinheiro fazendo uso da empresa, de modo que os suspeitos que demonstrarem evidências mais claras de práticas irregulares deverão ter suas contas bloqueadas e imediatamente serem reportados ao Coaf.

Este controle envolve dois fluxos de processos distintos: há a necessidade de realizar reportes de Comunicações de Operações Automáticas (COA), que são comunicações realizadas sem análise de mérito, e somente em função de valores previamente estabelecidos nas normas emitidas pelos órgãos reguladores, e reportes das Comunicações de Operações Suspeitas (COS), substancialmente mais complexos, que são efetuados levando-se em conta valores, partes envolvidas, modo de realização, meio e forma de pagamento, bem como outras características que possam indicar qualquer crime previsto na Lei no 9613 de 1998.

O fluxo do processo de investigação e envio das COA e das COS será detalhado no capítulo “3.3.3 Fluxo de Processo de Análise”.

### 3.3.1 Modo de operação atual

É possível observar uma dinâmica de organização do trabalho distinta entre os dois times que compõem o *squad*, isto é, o time de *analytics* e o time de operações. Desta forma, a análise do modo de operação do *squad* será também dividida entre os dois times e, ao final, será destacado como se dá a interface entre ambos.

O time de *analytics* é responsável por realizar projetos que aumentem a eficiência operacional do *squad*, atuando como uma célula especializada de suporte às atividades dos analistas de PLD. Os projetos possuem naturezas diversas, e geralmente são definidos ao início de cada trimestre, junto com a criação dos *Objective Key Results* (OKRs) referentes àquele período. Estes objetivos serão melhor explicados no capítulo “3.8 Definição de OKRs (*Objective Key Results*)”.

Uma vez definidos os projetos e os responsáveis por executá-los, são realizadas reuniões semanais de acompanhamento dos projetos, nos quais cada membro da equipe de *analytics* compartilha os resultados que foram alcançados até então, fornecendo assim, uma atualização do status do projeto.

O nome do time de *analytics* foi dado devido ao uso intenso de dados da *Fintech X* para resolver problemas da área e trazer eficiência ao time de operações. De modo geral, o time escreve códigos nas linguagens de programação Scala e Python em chamados "*notebooks*", que são scripts que realizam consultas aos dados armazenados na infraestrutura em nuvem da empresa (as chamadas *queries*), e permitem a transformação e visualização desses dados em larga escala sem que haja a necessidade de executar programas separados. Os dados consultados são provenientes das mais diversas fontes, entretanto, há três tipos de dados que mais interessam ao time, dada a natureza do trabalho em PLD:

- (i) Transações dos clientes utilizando o cartão de crédito;
- (ii) Movimentações na conta de pagamentos dos clientes;
- (iii) Informações cadastrais dos clientes.

Esses três conjuntos de dados fornecem uma visão do grau de risco de cada cliente quando os analistas de PLD os investigam. Dessa maneira, como grande parte do trabalho do time de *analytics* está em otimizar o trabalho da operação, estas são consideradas as fontes de dados mais consultadas.

O time de operações, composto por 9 analistas e 2 coordenadores de PLD, é responsável por efetivamente realizar o trabalho exigido pela Lei de Prevenção à Lavagem de Dinheiro. A rotina de trabalho deles não é primariamente baseada em projetos como ocorre no time de *analytics* - eles devem realizar o número de análises estabelecido como meta diária, e podem participar de projetos secundários, de caráter opcional. Eles possuem liberdade de organizar o seu cronograma como quiserem - não é necessário que trabalhem seguindo horários pré-estabelecidos, e podem dividir o seu tempo entre as investigações e os projetos secundários como lhes for mais conveniente.

Nota-se que os projetos secundários são uma maneira de enriquecer o trabalho dos analistas de PLD. Por seguirem uma rotina no dia-a-dia das análises, que envolve um trabalho relativamente repetitivo, uma vez que as investigações exigem que os analistas olhem sempre para as mesmas variáveis de investigação, os projetos acabam sendo a maneira de os analistas desenvolverem habilidades que não costumam exercer no dia-a-dia. Projetos já realizados no passado incluem, por exemplo:

- (i) Desenvolver uma metodologia de avaliação de qualidade das análises;
- (ii) Desenvolver o processo de recepção e treinamentos dos analistas novos que entrarem no *squad*;
- (iii) Planejar rituais do time, como as *stand-up meetings*, dentre outras.

A interface entre ambos os times é livre de qualquer restrição de comunicação, e a proximidade física entre as equipes facilita o contato diário. De forma geral, o time de *analytics* trabalha diariamente nos projetos necessários ao *squad*, e responde de forma reativa às demandas pontuais que surgem do time de operações. De modo geral, essas demandas são enviadas via mensagem virtual na plataforma de comunicação interna da empresa - o Slack - ou ao vivo, exigindo que o analista de PLD vá até a mesa do time de *analytics* ou marque uma reunião com alguns deles. Alguns exemplos de demandas incluem, por exemplo, a automação de algum processo repetitivo da operação, o desenvolvimento de uma *query* para extrair informações de uma base de dados específica, etc.

É necessário que haja um balanceamento de tarefas dentro do time de *analytics*, de modo que eles consigam contribuir com demandas pontuais da operação, mas que as horas de trabalho alocadas para resolver estas demandas não atrapalhe o andamento dos projetos que se dispuseram a fazer.

### 3.3.2 Tecnologia de identificação de suspeitos

Para a identificação de suspeitos de lavagem de dinheiro na base de usuários da *Fintech X*, foram criados alertas baseados em alguns parâmetros de comportamento envolvendo transações no cartão de crédito e movimentações financeiras. De forma geral, eles representam regras simples que traduzem exigências da circular nº 3461 do BACEN, que “consolida as regras sobre procedimentos a serem adotados na prevenção e combate às atividades relacionadas com os crimes previstos na Lei nº 9.613, de 3 de março de 1998.”

Entretanto, como a maior parte das regras descritas na circular do BACEN não explicitam valores específicos a serem observados - visto que o volume de capital e frequência de operações pode variar de uma instituição financeira para outra - cabe à equipe de *analytics* definir quais são os valores ótimos de identificação de modo que haja um equilíbrio entre a mitigação do risco de lavagem de dinheiro e a capacidade operacional de análise do time.

Os alertas funcionam da seguinte maneira: eles são programados por condições descritas em *Spark notebooks*, que são instâncias de uma plataforma de consulta aos dados em nuvem da *Fintech X*. Com as regras codificadas, basta executar o *notebook* - de maneira semelhante ao processo de se executar um programa - e ele retornará tabelas que representam as consultas feitas na nuvem. Essas tabelas, denominados *datasets*, já se encontrarão filtradas e contendo casos ordenados por risco.

O quadro a seguir mostra um resumo de todas as regras que eram utilizadas pela equipe de PLD para a identificação de casos suspeitos utilizando cartão de crédito. Os valores descritos foram modificados por um múltiplo arbitrário e as condições descritas pelas regras também foram alteradas por motivo de confidencialidade.

**Quadro 1 – Regras de identificação de suspeitos com cartão de crédito**

<b>Nome da regra</b>	<b>Descrição da regra</b>
Pré-pagamento	Capturam-se clientes que realizaram pré-pagamentos a partir de R\$ 5.000,00 (cinco mil reais), priorizando casos em que o montante supera em seis vezes o limite de crédito ou em dez vezes a renda inferida do cliente.
Concentração de compras em um mesmo estabelecimento	Capturam-se clientes que concentram pelo menos 80% (oitenta por cento) das compras em um estabelecimento, desde que a fatura seja de pelo menos R\$ 5.000,00 (cinco mil reais). Priorizam-se casos em que os gastos no estabelecimento concentrado supera em seis vezes o limite de crédito ou em dez vezes a renda inferida do cliente.
Desvios no padrão de consumo	Capturam-se clientes que, durante um período de trinta dias movimentaram menos de R\$150,00 (cento e cinquenta reais) no cartão, mas nos trinta dias seguintes superaram R\$7.000,00 (sete mil reais) em gastos. Também capturam-se clientes que movimentaram no máximo uma vez o cartão por trinta dias, mas nos trinta dias seguintes realizaram pelo menos 20 (vinte) transações.
Gastos acima da capacidade financeira	Capturam-se clientes com gastos acima de R\$ 12.000,00 (doze mil reais), priorizando casos em que os gastos superam em seis vezes o limite de crédito ou em quinze vezes a renda inferida do cliente.
Pedidos de aumento de limite	Capturam-se clientes que solicitaram mais de quarenta vezes aumento de limite nos últimos trinta dias, e também apareceram no alarme de gastos acima da capacidade financeira.
Compras em países monitorados pelo GAFI	Capturam-se clientes que fizeram compras em algum dos países de alto risco ou de jurisdição monitorada pelo GAFI.
Fraud ID com alta movimentação	Capturam-se clientes que providenciaram informações cadastrais falsas e estavam movimentando pelo menos R\$5.000,00 (cinco mil reais) nos sessenta últimos dias.
Contestação de compras	Capturam-se clientes que pediram estorno de ao menos R\$5.000,00 (cinco mil reais) após terem pago a fatura, priorizando casos em que o estorno supere em uma vez o limite de crédito ou em seis vezes a renda inferida do cliente.

Fonte: Elaborado pelo Autor

Já o quadro a seguir ilustra os alertas criados para capturar movimentações suspeitas de clientes utilizando a conta de pagamentos da *Fintech X*:

**Quadro 2 - Regras de identificação de suspeitos com conta de pagamentos**

<b>Nome da regra</b>	<b>Descrição da regra</b>
Transferências	Capturam-se os clientes que transacionaram pelo menos R\$40.000,00 (quarenta mil reais) por boleto ou TED de depósito ou transferência externa. Também detecta movimentações nas quais pelo menos 70% (setenta por cento) do que foi depositado é transferido para fora em até dois dias úteis.
Concentração de transferências para poucos beneficiários	Capturam-se pessoas físicas ou jurídicas que movimentam altos valores para poucas pessoas na base da <i>Fintech X</i> . Exemplo: um estabelecimento que só movimenta para uma conta na <i>Fintech X</i> e as transferências em média superam R\$ 400.000,00 (quatrocentos mil reais).
Boletos	Capturam-se clientes que realizaram ao menos quinze pré-pagamentos ou pré-pagamentos que superam em mais de seis vezes o limite de crédito, utilizando este saldo para pagar boletos de fatura de compras do cartão de crédito ou para pagamento de outras contas.
Mudança de comportamento	Capturam-se tanto clientes que estavam inativos (sem nenhuma movimentação na conta de pagamentos nos noventa dias anteriores da análise) e passaram a fazer mais de doze movimentações nos últimos trinta dias, assim como clientes que estavam com alta atividade (ao menos doze movimentações nos últimos noventa dias anteriores da análise) e se tornaram inativos nos últimos trinta dias.
Alta movimentação de clientes recentes	Capturam-se os clientes que estão com a conta ativa há menos de trinta dias e já movimentaram ao menos R\$50.000,00 (cinquenta mil reais) e que o montante da movimentação superar em, pelo menos, quinze vezes a renda mensal inferida.

Fonte: Elaborado pelo Autor

Para que seja possível obter uma compreensão holística do funcionamento de um alerta, tomar-se-á como exemplo o alerta de pré-pagamento. A seguir, será apresentado o pseudocódigo (uma forma genérica de escrever um algoritmo) por trás do alerta.

**Figura 11 - Pseudo-código do alerta de pré-pagamento**

```

Algoritmo de atribuição de risco de pré-pagamento
// Atribui grau de risco do alerta para cliente suspeito de 0 a 3, sendo 3 o mais arriscado
VAR renda, limite, pre_pagamento, referencia, risco: REAL
INÍCIO
  LEIA (renda, limite, pre_pagamento, referencia)
  SE pre_pagamento >= referencia ENTÃO
    SE pre_pagamento >= 6 * limite E pre_pagamento >= 10 * renda ENTÃO
      risco ← 3
    SENÃO
      SE pre_pagamento >= 6 * limite OU pre_pagamento >= 10 * renda ENTÃO
        risco ← 2
      SENÃO
        risco ← 1
      FIM-SE
    FIM-SE
  SENÃO
    risco ← 0
  FIM-SE
FIM

```

Fonte: Elaborado pelo Autor

O pseudocódigo simplificado acima foi elaborado para exemplificar como funcionaria a lógica de atribuição de risco baseada em regras. Para que a lógica do algoritmo esteja integrada no formato de *dataset*, entretanto, são necessários diversos passos de checagem do tipo do dado de input e output, para garantir que não haja quebra de compatibilidade com os sistemas de *data warehouse* da *Fintech X*.

### 3.3.3 Fluxo de processo de análise


Como citado anteriormente, há dois processos de investigação e reportes bastante distintos: as COA e as COS. Porém, será dado foco à análise do fluxo das Comunicações de Operações Suspeitas (COS), mais pertinente ao Trabalho de Formatura, uma vez que são o único tipo de investigação passível de se tornarem reportes ao Coaf. Para esta análise, será utilizada a metodologia de modelagem de processos.

A modelagem do processo de investigação de um cliente suspeito se encontra na página seguinte. Partiu-se da premissa que o processo modelado só termina quando um cliente suspeito

de fato é reportado ao Coaf - caso o cliente da investigação atual não apresente risco de lavagem de dinheiro esta investigação é terminada, e a investigação de outro caso suspeito é iniciada.



Figura 12 – Processo de Comunicação de Operação Suspeita (COS)



Fonte: Elaborado pelo Autor

### 3.4 Problemas e desafios identificados

Após uma apresentação geral do funcionamento da área, fica nítido que há alguns problemas a serem atacados no funcionamento da área de PLD da *Fintech X*. Antes de listar os problemas é interessante definir de uma maneira objetiva o que deve ser considerado um problema. Utilizou-se como definição de problema qualquer processo sendo realizado de maneira subótima (seja na divisão de trabalho, método de trabalho ou qualquer outra decisão) e que esteja impedindo ou atrapalhando o alcance da visão estratégica do *squad*.

Com esse conceito para o valor do negócio segue-se a proposta de Hayes et al. (2005) para argumentar que toda a operação (englobando os processos principais e de apoio) deve estar alinhada com a proposta de valor que deve ser gerada pelo negócio. Hayes et al. (2005) analisam a operação sobre uma lógica de categorias de decisão (ex: capacidade, estrutura da rede, tecnologias da informação, processos de aprendizado, terceirização, verticalização) e têm como principal argumento que essas decisões devem ser alinhadas com a estratégia (verticalmente) e entre si (horizontalmente). Outro argumento forte que os Autores utilizam, baseados no conceito de foco da operação, é que se deve despender recursos unicamente naquilo que seja condizente com a proposta de valor.

Portanto, considerando-se que o *squad* em questão possui a missão clara de mitigar o risco regulatório ao qual a instituição financeira está exposta no que tange a Prevenção à Lavagem de Dinheiro, foi determinado que os problemas a serem atacados seriam justamente o baixo desempenho do time em cada uma das métricas citadas na seção "3.2 Dados de Produtividade". O quadro a seguir mostra os principais problemas identificados, e sob a responsabilidade de qual subequipe eles se encontram. Não foram selecionados um grande número de problemas adicionais porque a análise se tornaria demasiadamente complexa e poderia distrair a equipe do que era realmente mais urgente atacar neste contexto de ganho de eficiência no *squad*.

**Quadro 3 - Problemas identificados no *squad* de PLD**

<b>Time responsável</b>	<b>Problema</b>
<i>Analytics</i>	<ul style="list-style-type: none"> <li>• Baixa conversão de casos para reportes do Coaf</li> </ul>
Operação	<ul style="list-style-type: none"> <li>• Número insuficiente de casos analisados por mês</li> <li>• Nota de qualidade insatisfatória dos reportes realizados</li> </ul>

Fonte: Elaborado pelo Autor

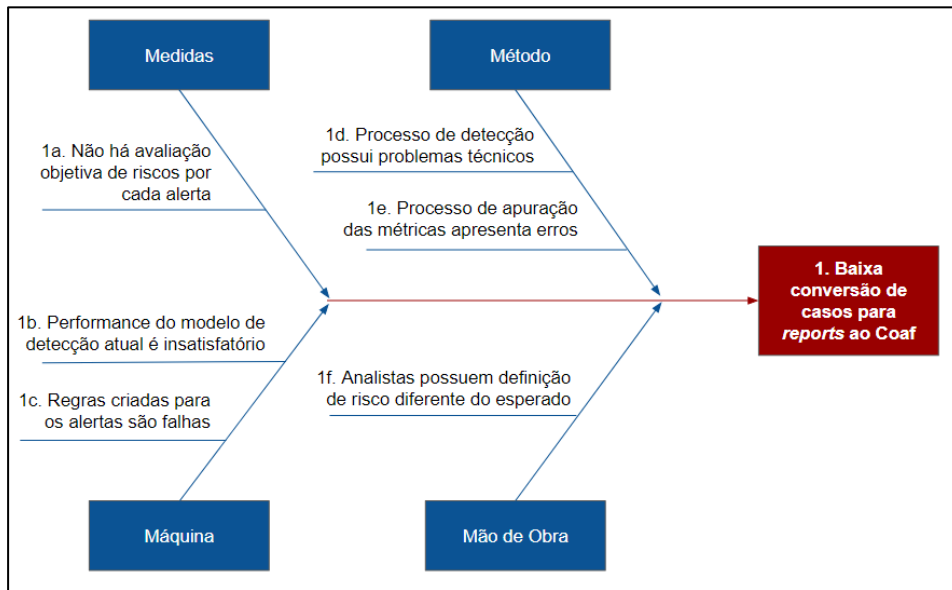
### 3.5 Identificação das causas raízes

Para estabelecer hipóteses sobre as causas raízes dos problemas em cada uma das etapas, foram utilizados Diagramas de Causa e Efeito. Após o levantamento das causas, foi realizada uma descrição mais completa de cada uma delas. Como não havia fatores relacionados à matéria prima ou meio ambiente, as espinhas grandes referentes a esses elementos nos diagramas foram omitidas (KUME, 1993).

#### 3.5.1 Problema 1: Baixa conversão de casos para reportes do Coaf

O diagrama a seguir ilustra as principais hipóteses de causas raízes para o problema que se encontra sob a responsabilidade do time de *analytics*, a “Baixa conversão de casos para reportes do Coaf”.

**Figura 13 - Diagrama de Causa e Efeito para o Problema 1**



Fonte: Elaborado pelo Autor

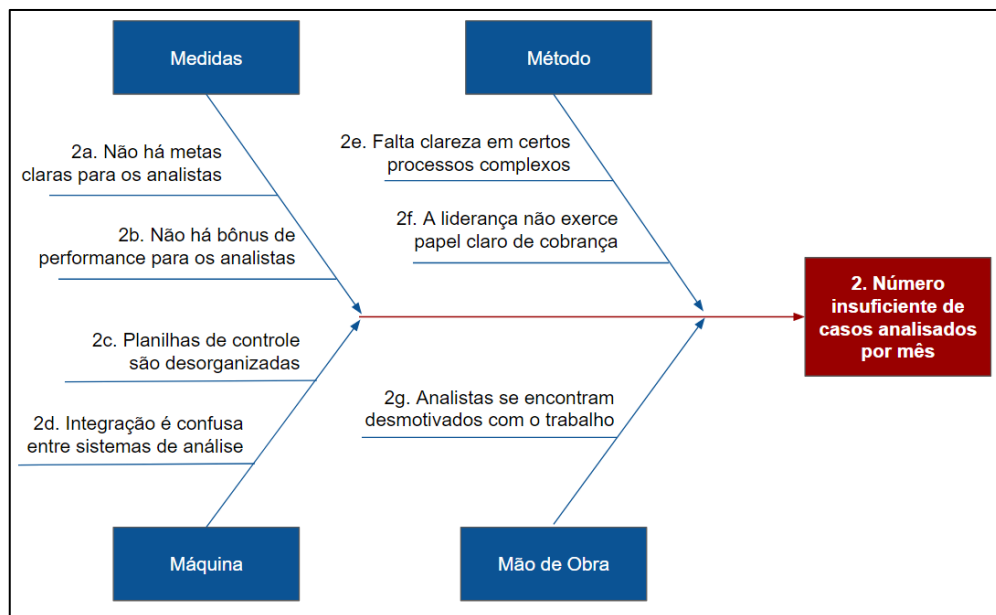
As causas levantadas são discutidas mais a fundo abaixo:

- **1a. Não há avaliação objetiva de riscos por cada alerta:** Os diferentes alertas que foram criados para a detecção de potenciais lavadores de dinheiro possuem graus de risco diferentes, entretanto, foi estabelecido um número mínimo de casos que deveriam ser investigados de cada um sem se levar em conta seu risco. Dessa forma, é possível que alertas que possuem baixa conversão (ou seja, denotam menos risco) estejam recebendo um número de análises igual ou até maior do que um alerta de alto risco, o que contribuiria para uma queda na taxa média geral de conversão de casos suspeitos para reportes enviados.
- **1b. Performance do modelo de detecção atual é insatisfatório:** As regras de detecção vigentes de cada alerta eram relativamente simples, e portanto, poderiam não ser capazes de detectar padrões complexos de lavagem de dinheiro, e poderiam estar apresentando um alto número de falso-positivos.
- **1c. Regras criadas para os alertas são falhas:** As regras criadas em código foram traduzidas de normas gerais do BACEN, que por serem aplicáveis a todas as instituições financeiras, são bastante genéricas. É possível que nesta interpretação das regras, a realidade da *Fintech X* seja diferente da de outras instituições financeiras, e exigiria uma compreensão diferente das normas.

- **1d. Processo de detecção possui problemas técnicos:** Devido ao processo de detecção depender da disponibilidade da infraestrutura de dados da empresa, se houver qualquer erro no processamento desses dados, é possível que as tabelas tenham como *output* alguns casos que não representem alto risco à instituição.
- **1e. Processo de apuração das métricas apresenta erros:** O cálculo das métricas de conversão é feito de forma automatizada em uma planilha no software Google Sheets, e é possível que haja um erro no cálculo das métricas que resulte em um número de conversões aquém do desejado.
- **1f. Analistas possuem definição de risco diferente do esperado:** Mesmo que os casos alarmados possuam um grau considerável de risco, se os analistas da operação possuem definições de risco diferente das do time de *analytics*, é possível que eles descartem risco de lavagem de dinheiro em casos suspeitos, o que contribuiria para diminuir a métrica de conversão de casos analisados para reportes ao Coaf.

### 3.5.2 Problema 2: Número insuficiente de casos analisados por mês

**Figura 14 - Diagrama de Causa e Efeito para o Problema 2**



Fonte: Elaborado pelo Autor

As causas levantadas são discutidas abaixo:

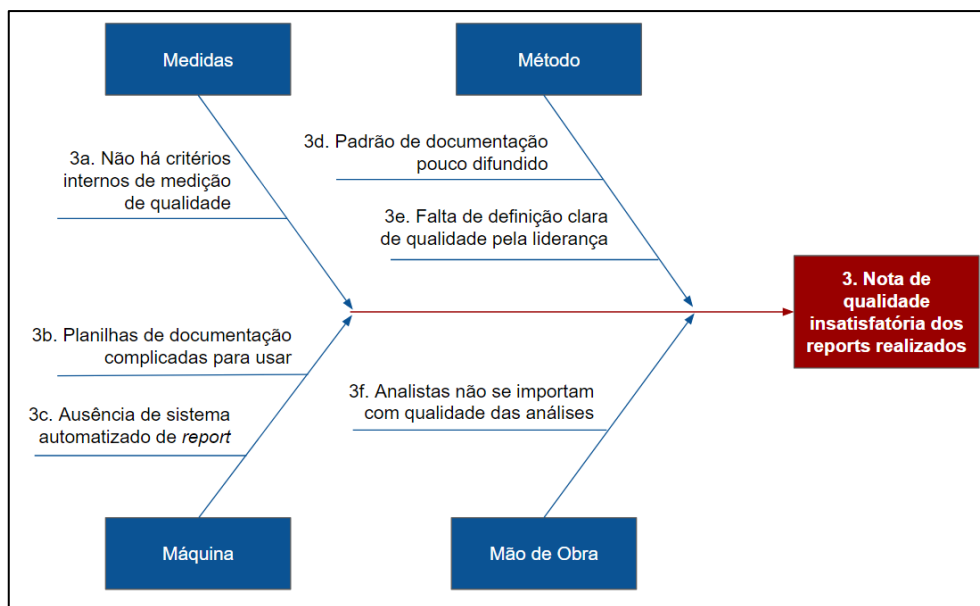
- **2a. Não há metas claras para os analistas:** Os analistas de PLD, individualmente, não possuem metas de quantas análises deveriam fazer. Embora eles tenham como referência o número de 4 análises por dia - um valor que foi determinado pela líder do *squad* de Compliance - não havia um controle robusto sobre quanto cada analista investigava por mês, e geralmente o número divulgado internamente era o número agregado de análises realizadas em conjunto pelo *squad*. Isso diminuía o senso de responsabilidade individual dos analistas com o número de análises que deveriam ser feitas.
- **2b. Não há bônus de performance para os analistas:** Os mecanismos de incentivos para realizar mais análises tampouco eram claros - além de os analistas não terem uma noção de responsabilidade forte sobre as análises, eles não seriam remunerados a mais se realizassem mais investigações do que a média, o que provocava certa inércia na performance de cada um deles.
- **2c. Planilhas de controle são desorganizadas:** As planilhas de controle utilizadas pelos analistas eram desorganizadas. Essas planilhas eram utilizadas primariamente para que eles pudessem registrar as informações mais relevantes sobre cada suspeito, de modo que a elaboração do reporte ao Coaf fosse agilizada (caso o suspeito tivesse risco suficiente). Entretanto, pela maneira com que a planilha foi construída, havia um número excessivo de abas, em uma ordem não muito lógica, e sem células de inputs pré-determinados (função chamada de “Validação de Dados” no Google Sheets). Isso aumentava o tempo de análise e induzia a erros operacionais.
- **2d. Integração é confusa entre sistemas de análise:** Para completar uma investigação, os analistas em geral devem usar ao menos quatro sistemas diferentes: a planilha de controle de informações da investigação, o “Backoffice” (que reúne todas as informações cadastrais dos clientes dentro da *Fintech X*, bem como suas movimentações financeiras), a planilha de registro de tratativas e reportes ao Coaf, e o sistema de comunicação por emails utilizado pela empresa. Além disso, era comum que analistas criassem suas próprias ferramentas que auxiliassem seu trabalho, como por exemplo, planilhas para realizarem cálculos de concentração de gastos em determinado lojista. O grande número de ferramentas fazia com que os analistas perdessem tempo trocando de uma plataforma para outra.
- **2e. Falta clareza em certos processos complexos:** Algumas investigações mais complexas, como por exemplo, as que envolvem quadrilhas operando com uma grande

rede de pessoas, são difíceis de serem realizadas, e muitos analistas se sentem inseguros sobre qual a melhor maneira de conduzir esses casos. Não há nenhuma documentação ou orientação com a explicação desses casos mais complexos, e analistas mais juniores acabam demorando um tempo considerável para entender os esquemas de atuação desses grupos e também para documentar a investigação.

- **2f. A liderança não exerce papel claro de cobrança:** Os coordenadores de PLD foram promovidos há pouco tempo, e ainda não possuíam habilidades de liderança plenamente desenvolvidas. Portanto, era comum que eles fossem brandos com os analistas em termos de cobrança por desempenho, e não havia a promoção de um ambiente que estimulasse a alta performance de todos da operação.
- **2g. Analistas se encontram desmotivados com o trabalho:** Alguns analistas de PLD se encontravam desmotivados com a natureza do trabalho, que podia ser mecânico e operacional. Além disso, a falta de atividades integrativas e oportunidades de ascensão de carreira contribuíam para que os analistas não se sentissem inteiramente motivados com o *squad*.

### 3.5.3 Problema 3: Notas de qualidade insatisfatória dos reports realizados

**Figura 15 - Diagrama de Causa e Efeito para o Problema 3**



Fonte: Elaborado pelo Autor

As causas levantadas são discutidas abaixo:

- **3a. Não há critérios de medição de qualidade:** Até então, a única métrica de qualidade utilizada para avaliar os reportes gerados era a nota oficial do Coaf. Entretanto, não havia um sistema de medição de qualidade interno que permitisse, posteriormente, comparar as notas dadas internamente com as notas oficiais. Uma vez que os critérios utilizados pelo Coaf não eram divulgados, tornava-se difícil saber exatamente quais eram os pontos de melhoria dos reportes insatisfatórios.
- **3b. Planilhas de documentação complicadas para usar:** Os analistas de PLD, após a conclusão de uma tratativa e um reporte ao Coaf, deveriam realizar o registro em uma planilha de documentação separada, que centralizava informações como o número de protocolo do reporte enviado ao Coaf, a data de envio, informações básicas do cliente, etc. Esta planilha apresentava defeitos semelhantes à planilha de controle das investigações, como excesso de abas e células sem Validação de Dados. Como o preenchimento da planilha muitas vezes se dava de forma simultânea ao envio do reporte pelo sistema do Coaf, e desmotivação gerada pela má experiência de uso da planilha poderia fazer com que o analista produzisse um reporte de baixa qualidade.
- **3c. Ausência de sistema automatizado de reporte:** Os reportes enviados pelo sistema do Coaf exigiam o input manual de informações em cada campo, o que gerava desgaste dos analistas e desânimo ao longo do processo. A instabilidade do sistema do Coaf também era um fator de complicação, uma vez que quando o site ficava fora do ar, as informações que estavam sendo digitadas eram perdidas, o que gerava grande frustração por parte dos analistas.
- **3d. Padrão de documentação pouco difundido:** O modo de escrever de cada analista de PLD apresentava grande variação e isso era uma das possíveis explicações às notas insatisfatórias do Coaf. *Reports* com erros ortográficos e gramaticais eram de modo geral vistos como menos profissionais, o que poderia ser prejudicial para a média de qualidade percebida. A quantidade de detalhes e a profundidade das análises também eram levadas em consideração pelo Coaf, e estes fatores também variavam muito de analista para analista.
- **3e. Falta de definição clara de qualidade pela liderança:** Os coordenadores de PLD, devido à falta de experiência descrita na seção anterior, também apresentavam uma postura pouco proativa em instaurar parâmetros de avaliação de qualidade dos reportes, o que contribuía para que os analistas continuassem escrevendo análises cada um do seu jeito.



- **3f. Analistas não se importam com a qualidade das análises:** Os analistas de PLD, devido a uma combinação de falta de liderança, e processos e ferramentas mal elaborados na área, pareciam não se importar muito com a qualidade das análises que produziam, uma vez que não sofreriam consequências por reportes mal avaliados.

### 3.6 Levantamento de soluções

Para cada causa-raiz, foram elaboradas uma ou mais propostas de solução. Entretanto, devido à diferença na natureza dos problemas de *analytics* e dos problemas da operação, os processos de levantamento das soluções foram conduzidos de forma levemente diferente.

Quanto ao problema “Baixa conversão de casos para reportes ao Coaf”, sob a responsabilidade do time de *analytics*, foi elaborada uma sessão de *brainstorming* somente com os membros da equipe, uma vez que o levantamento de ideias exigia grande conhecimento técnico de dados.

Para os dois problemas seguintes, sob a responsabilidade do time de operações, foram envolvidos todos os analistas de PLD e seus coordenadores, em um processo mais longo que o realizado com o time de *analytics*.

Foi realizada uma pesquisa anônima e qualitativa, enviada a cada um dos analistas de PLD, para que eles pudessem dar opiniões com maiores detalhes sobre cada um dos problemas elencados, e o que exatamente eles achavam que seria mais efetivo ter. Como o time de *analytics* não possui uma visão tão granular sobre as complexidades do dia-a-dia da operação, foram incluídos campos na pesquisa para que os próprios analistas pudessem dar sugestões, e elencar desejos de mudanças que poderiam ser implementados. Isto reduziria uma etapa grande de planejamento da solução por parte do time de *analytics*, e seria mais direcionada a necessidades encontradas pelas próprias pessoas que vivem a operação.

No final, era esperado que ambos os processos de levantamento de soluções contribuíssem para um mesmo objetivo em comum: gerar o maior número de ideias possível para solucionar as causas-raízes elencadas. Os quadros a seguir resumem todas as soluções que foram elencadas em ambos os processos.

**Quadro 4 - Propostas de soluções para as causas-raízes do Problema 1**

<b>Causa-raiz</b>	<b>Proposta de solução</b>
1. Baixa conversão de casos para reportes ao Coaf	
1a. Não há avaliação objetiva de riscos por cada alerta	Criar avaliação de riscos e dimensionamento de quantidade de alertas
1b. Performance do modelo de detecção atual é insatisfatório	Criar um novo modelo de detecção de suspeitos de lavagem de dinheiro
1c. Regras criadas para os alertas são falhas	Revisar e aprimorar regras para os alertas
1d. Processo de detecção possui problemas técnicos	Validar processo de detecção com time de engenharia de dados da empresa
1e. Processo de apuração das métricas apresenta erros	Criar modelo mais robusto e confiável de apuração de métricas
1f. Analistas possuem definição de risco diferente do esperado	Alinhar e documentar definição de risco entre analistas de PLD e time de <i>analytics</i>

Fonte: Elaborado pelo Autor

**Quadro 5 - Propostas de soluções para as causas-raízes do Problema 2**

<b>Causa-raiz</b>	<b>Proposta de solução</b>
2. Número insuficiente de casos analisados por mês	
2a. Não há metas claras para os analistas	Elaborar sistema de metas claras para analistas
2b. Não há bônus de performance para os analistas	Criar política de bônus por performance aos analistas
2c. Planilhas de controle são desorganizadas	Criar modelo de planilha mais linear e descomplicado
2d. Integração é confusa entre sistemas de análise	Desenvolver nova plataforma que integra diferentes sistemas
2e. Falta clareza em certos processos complexos	Mapear, documentar e alinhar processos complexos entre todos os analistas
2f. A liderança não exerce papel claro de cobrança	Criar treinamento de liderança para os coordenadores de PLD
2g. Analistas se encontram desmotivados com o trabalho	Criar plano de engajamento e aumento de motivação dos analistas

Fonte: Elaborado pelo Autor

**Quadro 6 – Propostas de soluções para as causas-raízes do Problema 3**

<b>Causa-raiz</b>	<b>Proposta de solução</b>
3. Nota de qualidade insatisfatória dos reportes utilizados	
3a. Não há critérios internos de medição de qualidade	Elaborar modelo interno de avaliação de qualidade das investigações
3b. Planilhas de documentação complicadas para usar	Criar modelo simplificado de planilha de documentação de investigações
3c. Ausência de sistema automatizado de reporte	Criar sistema de elaboração e envio automatizado de reporte
3d. Padrão de documentação pouco difundido	Criar e divulgar padrão de documentação de reporte entre os analistas de PLD
3e. Falta de definição clara de qualidade pela liderança	Engajar a liderança a cobrar e disseminar os padrões de qualidade estabelecidos
3f. Analistas não se importam com qualidade das análises	Criar mecanismos de incentivo para garantir a qualidade dos reportes


Fonte: Elaborado pelo Autor

### 3.7 Priorização de soluções

Para a priorização de soluções, foi feita uma sessão de avaliação de todas as possíveis soluções em uma reunião com o time de *analytics* e os coordenadores de PLD, no qual o grupo como um todo passava por cada uma das soluções e as inseria em uma Matriz de Impacto X Esforço.

A matriz resultante com os projetos já “plotados” é a seguinte.

**Figura 16 - Matriz de Impacto X Esforço para as soluções propostas**



Fonte: Elaborado pelo Autor

Com os projetos posicionados na matriz, seria necessário escolher um critério para priorização das soluções propostas. Embora o primeiro impulso do time fosse escolher somente projetos localizados no quadrante de *Quick-wins*, como o *squad* de PLD necessitava de uma estruturação de longo-prazo e não havia pressão por prazos nem restrição de recursos, foi decidido que seriam escolhidos os projetos que trouxessem maior impacto ao *squad*, independentemente de seu esforço de implementação.

Dessa forma, foram escolhidas as soluções às causas-raízes 1a, 1b, 2d, 2g e 3a. Esses projetos foram transformados em OKRs, como será explicitado no capítulo seguinte.

### 3.8 Definição de OKRs (*Objective Key Results*)

A *Fintech X* adota, por toda a empresa, o modelo de *Objective Key Results* (OKRs). Os objetivos globais da organização, alinhados à sua estratégia de longo prazo, são monitorados de forma constante, e somente são alterados quando a Diretoria acredita ser necessária alguma mudança estratégica da empresa, ou quando influências externas exigem uma alteração nos planos.

Além disso, cada *Tribe* e *Squad* da empresa é responsável em definir seus próprios OKRs, que indicam de forma geral quais vão ser os principais objetivos a serem perseguidos durante

determinado trimestre. Esses OKRs são então levados aos OKRs *Meetings*, com a presença da Diretoria inteira, e são validados pela alta gestão. Entretanto, por conta do alto número de times criando seus próprios OKRs, a Diretoria não possui capacidade de monitorar cada um deles, e portanto dá autonomia para que cada time se encarregue de encontrar um jeito de satisfazer o objetivo, e depois reportar se foram bem-sucedidos ou não.

Não há nenhum tipo de bonificação para o cumprimento das metas ou punição pelo não-cumprimento delas - os OKRs, nesse contexto, possuem um papel de simplesmente fornecer um direcionamento estratégico para a área, e fazer com que todos do time tenham um norte com os projetos que realizam. É comum, portanto, que os gestores criem metas arrojadas para motivar a equipe.

Com os principais problemas a serem atacados já definidos, o *squad* de PLD identificou as principais ações que poderiam ser feitas para solucionar os problemas elencados na seção anterior, elaborou os seus OKRs e validou-os com a Diretoria, de modo que eles estivessem alinhados com os OKRs definidos para a *Defense Tribe*. Como os objetivos definidos para PLD faziam perfeito sentido com a missão do *squad*, eles foram aprovados sem ressalvas, e não foi necessário realizar ajustes para adequação à estratégia geral da *Tribe*.

Com o objetivo de simplificar a implementação das soluções selecionadas na seção anterior, foram elaborados dois objetivos distintos: um sob responsabilidade do time de *analytics*, e outro sob responsabilidade do time de operação (embora com grande envolvimento tático e estratégico do time de *analytics*). Essa distinção traz clareza em relação aos “donos” de cada objetivo e permitiria um planejamento e execução de cada projeto de forma paralela.

Os OKRs do *squad* de PLD para o primeiro trimestre de 2019 podem ser observados no quadro elaborado a seguir.

**Quadro 7 - Quadro-resumo dos OKRs definidos**

<b>Objetivo</b>	<b>Métrica</b>	<b>Meta Q1/19</b>	<b>Nome do projeto</b>
<b>Objetivo 1: Aumentar a precisão dos alertas de PLD</b>			
1.1 Criar avaliação de riscos e dimensionamento de quantidade de alertas	Taxa média de conversão de casos analisados para reportes (em %)	30%	<i>Risk-based Approach</i>
1.2 Criar um novo modelo de detecção de suspeitos de lavagem de dinheiro	Taxa média de conversão de casos analisados para reportes provenientes do modelo de <i>Machine learning</i> (em %)	40%	Criação do modelo de <i>Machine learning</i>
<b>Objetivo 2: Aumentar a produtividade dos analistas de PLD</b>			
2.1 Desenvolver nova plataforma de registro de investigações que integra diferentes sistemas	Número de investigações realizadas por dia por analista	4,0	Sistema de <i>backoffice</i>
2.3 Elaborar modelo interno de avaliação de qualidade das investigações	Nota média de avaliação de reportes ao Coaf (de 1 a 4)	3,5	Modelo de <i>Quality Assessment</i>
2.2 Criar plano de engajamento e aumento de motivação dos analistas	Nota média de satisfação dos analistas em pesquisa de engajamento (de 0 a 10)	9	Plano de engajamento

Fonte: Elaborado pelo Autor

Uma vez definidos os OKRs, passou-se para a elaboração da execução de cada um dos planos delineados. Um ponto importante é que os resultados advindos dos projetos provavelmente se manifestariam, em sua maior parte, no segundo trimestre de 2019, o que tornaria difícil a tarefa de atingir a meta já no mesmo trimestre de implementação dos projetos. A Diretoria da empresa concordou, portanto, em deixar as metas arrojadas acima para o primeiro trimestre, mas repeti-las para o segundo trimestre caso os ganhos gerados pelos projetos não pudessem ser observados de imediato.





## 4 DESENVOLVIMENTO DO TRABALHO

Neste capítulo, será descrito o desenvolvimento e implantação dos planos referentes aos problemas que foram diagnosticados na seção anterior.

### 4.1 Planejamento da implementação

A implementação dos projetos para solucionar os OKRs propostos, principalmente por conta da variedade de tarefas que seriam feitas, se provou bastante desafiadora. O Autor do Trabalho de Formatura e o time de *analytics* criaram uma primeira proposta de sequência de atividades separadas por objetivo, de modo a paralelizar o desenvolvimento de cada frente de trabalho e garantir uma visão mais ampla de tudo que deveria ser feito, bem como quais tarefas poderiam ser delegadas. O Gráfico de Gantt elaborado pela equipe, a ser seguido como um macro-planejamento para o projeto, pode ser conferido na página seguinte.

Figura 17 - Gráfico de Gantt com o planejamento do projeto



Fonte: Elaborado pelo Autor

Por conta da paralelização das frentes, com diferentes pessoas trabalhando em diferentes projetos, foi possível agilizar a execução do macro-projeto de ganho de escalabilidade e eficiência operacional, e buscar resultados ainda no primeiro trimestre de 2019. É possível notar que os tempos de desenvolvimento de cada um dos sub-projetos da operação (“Sistema de *Backoffice*”, “Modelo de Quality Assessment” e “Plano de engajamento”) é geralmente maior do que os dos dois primeiros objetivos, que são primariamente conduzidos pelo time de *Analytics* (“Risk Based Approach”, “Criação do Modelo de *Machine learning*”). Isso ocorre porque os analistas de PLD trabalhariam nesses sub-projetos em regime de meio período, uma vez que eles ainda possuem investigações para conduzir no dia-a-dia, enquanto o time de *Analytics* estaria trabalhando em regime integral em suas iniciativas.

Os capítulos a seguir detalham as ações que foram tomadas para atingir cada objetivo, e ao final, será apresentado um resumo de todas as tarefas que foram realizadas.

#### **4.2 Objetivo 1: aumentar a precisão dos alertas de PLD**

Como observado no capítulo “3.2 Dados de produtividade”, a taxa de conversão de casos investigados para reportes ao Coaf estava estagnada há alguns meses. De fato, não havia um trabalho contínuo de melhoria da precisão dos alertas para que suspeitos mais arriscados fossem identificados.

Tendo isto em mente, o time de *analytics* elaborou uma nova estratégia para aumentar a eficiência dos alertas. A ideia inicial seria alavancar o uso das tecnologias mais recentes de análise de dados - principalmente pelo uso de algoritmos de *machine learning* - e substituir toda a infraestrutura de geração de alertas atual por modelos que seriam capazes de prever os casos com maior probabilidade de detecção de lavadores de dinheiro.

O fato da *Fintech X* apresentar uma operação pautada em metodologias ágeis, e também com grande robustez em sua infraestrutura tecnológica e de dados, permite que desde estagiários até gerentes alavanquem suas análises e ferramentas com base em tecnologias de ponta, e tenham acesso a uma quantidade imensa de dados. Desta forma, o emprego de uma solução inovadora e moderna, que poderia ser entregue em poucos meses, se torna uma vantagem competitiva em comparação aos bancos tradicionais.

Entretanto, a abordagem apresentava alguns riscos. Afinal, seria um projeto que consumiria um tempo relativamente longo de trabalho e poderia não trazer ganhos significativos - ou até mesmo piorar os indicadores atuais. Assim, foi elaborado um

planejamento de geração de alertas que mesclaria aspectos do sistema atual com a implementação gradual do novo modelo de *machine learning*.

Como, em teoria, o modelo é capaz de melhorar sua performance conforme aumenta a disponibilidade de dados passados, foi acordado que o ideal seria otimizar aspectos do sistema atual e gerar alertas com o novo modelo que seriam analisados somente após os alertas originais terem sido finalizados. Isso possibilitaria que alguns resultados preliminares da performance do modelo pudessem ser avaliados, mas permitiria que não fossem colocados todos os recursos em uma tecnologia sobre a qual não tínhamos total certeza que faria um trabalho melhor que o sistema atual.

#### 4.2.1 Geração de alertas

A estratégia encontrada foi seguir com dois modelos de distribuição de alertas de forma paralela. Um deles, chamado de “alarmes mínimos”, reuniria alertas com valores-referência exigentes, e que representariam os casos mais extremos de suspeitos de lavagem de dinheiro, que teriam de ser analisados de qualquer maneira. Desta forma, toda a capacidade operacional da equipe seria primeiramente direcionada para este tipo de alerta, e caso os analistas conseguissem investigar todos os casos deste modelo, passariam a investigar clientes oriundos do segundo modelo, envolvendo o algoritmo de *machine learning*.

Naturalmente, para o primeiro modelo, há duas variáveis cruciais que devem ser determinadas: os valores-referência para cada alarme, e o número de casos a ser entregue para os analistas. Há uma relação de dependência entre as variáveis: quanto mais altos são os valores de corte, menos casos, em teoria, haverá para serem analisados. Ou, caso o aumento no valor de corte siga a taxa de crescimento de aquisição de clientes da *Fintech X*, espera-se que o número de casos a serem analisados siga relativamente constante ao longo dos meses.

Já para o segundo modelo, como o modelo de *machine learning* irá ter como variável de saída somente a probabilidade de o cliente ser um lavador de dinheiro, é possível ordenar todos os clientes que estejam passando pelo modelo em ordem decrescente de *score* de risco, e entregar a lista para os analistas investigarem os casos na ordem em que aparecem. Este processo, porém, só teria início após os analistas terem terminado de analisar os casos oriundos do primeiro modelo. Caso eles não conseguissem atingir a meta mensal de investigações com os casos dos alarmes mínimos, eles sequer começariam os casos entregues pelo modelo de *machine learning*.

#### 4.2.2 Tecnologias a serem utilizadas

Para a elaboração dos alertas mínimos, foi decidido que eles deveriam ser completamente automatizados, parametrizados, e de fácil interpretação pelos reguladores - características que não eram presentes no modelo de operação que existia até então, uma vez que os códigos elaborados em *notebooks* eram de difícil leitura e compreensão. Isto exigiria a adoção de uma plataforma inteiramente nova, diferente dos *notebooks* utilizados.

Uma forma comum na *Fintech X* de se gerar tabelas dinâmicas, com informações que são atualizadas diariamente, é através da produção dos chamados *datasets*, que consistem em tabelas contendo alguma lógica por trás, e que retornam somente informações referentes à lógica implementada.

Os *datasets* muitas vezes são gerados a partir das consultas à base de dados da *Fintech X*, potencialmente envolvendo alguma transformação dos dados retornados. Entretanto, a diferença é que o *dataset* aplica a lógica das queries de forma perene, e toda vez que o *data warehouse* da *Fintech X* é atualizado (o que ocorre uma vez por dia), o *dataset* criado retorna valores diferentes.

Para que os casos gerados em um dia não sejam perdidos no dia seguinte, é possível criar os chamados *dataset series*, que anexam informações de *datasets* gerados no passado e servem como uma espécie de histórico. Este foi o caminho escolhido pelo Autor e sua equipe de *analytics*. A criação de um *dataset series* seria feita na linguagem de programação Scala, bastante adequada para a manipulação de dados na escala de *big data*, e que foi a linguagem escolhida como padrão pela *Fintech X* para a criação deste tipo de operação. Após o desenvolvimento do código, este seria integrado ao código-fonte do *data warehouse* da *Fintech X*, estando disponível para qualquer um que quisesse utilizá-lo, e sendo atualizado diariamente junto com todos os outros *datasets* da empresa.

A parte técnica do código diz respeito ao campo de estudo de Engenharia de Software, e neste Trabalho de Formatura, no capítulo 4.2.3 “Detalhamento da solução”, será dado um destaque maior à análise realizada sobre o ganho de eficiência da solução, e como a análise se relaciona ao objetivo de garantir aumento de escalabilidade da área de Prevenção à Lavagem de Dinheiro na *Fintech X*.

Já em relação à criação do modelo de *machine learning*, este seria feito na linguagem de programação Python, seguindo todo o fluxo de desenvolvimento de modelos da *Fintech X*.

Existe um processo automatizado de criação de modelos de *machine learning* que reduz drasticamente o tempo de treino e implementação do modelo em produção, uma vez que muitas etapas desse processo são padrão, independente do problema de negócio que está sendo solucionado.

Os pormenores do código do modelo, na visão do Autor, tampouco são relevantes para este Trabalho de Formatura, e no detalhamento da solução será dado um destaque maior ao processo de criação do modelo e a lógica por trás de seu funcionamento na prática.

### **4.2.3 Detalhamento da solução**

#### **4.2.3.1 Risk-based Approach**

Com o objetivo de se determinar os valores-referência ótimos para cada tipo de alerta, foi feito um estudo seguindo o chamado *Risk-based approach* (RBA) - ou “abordagem baseada em risco (ABR)”. Esta metodologia, utilizada de forma crescente no universo de Compliance e Prevenção à Lavagem de Dinheiro por instituições financeiras ao redor do mundo, prevê que os países - e por consequência, suas empresas - devem direcionar seus recursos e aplicar medidas preventivas mais intensas nos setores ou atividades específicas de forma proporcional ao risco de lavagem de dinheiro identificados. (FATF, 2012)

Embora a noção de alocar recursos de forma proporcional ao risco possa parecer trivial, esta era uma prática pouco disseminada entre empresas do setor financeiro há poucos anos. Isto porque PLD, considerada uma atividade de Defesa, historicamente não recebia muitos recursos para ser otimizada, visto que não é uma atividade que traz receita às empresas. Em alguns casos, era comum que apenas fossem seguidas as diretrizes de investigação determinadas pelo Coaf, sem uma alocação inteligente de tempo e recursos nos casos que fossem de fato os mais arriscados.

Com o intuito de modernizar a gestão de PLD na *Fintech X*, o Autor e seu time de *analytics* trabalharam na implementação do RBA no *squad* de PLD. Assim, o estudo do risco de cada tipo de alerta teria como resultado final os valores-referência que deveriam ser incluídos em cada tipo de alarme mínimo, e que seria inserido no código de seu respectivo *dataset*.

Os riscos inerentes das operações e produtos estão relacionados com o comportamento transacional dos clientes a partir das possibilidades oferecidas por cada produto. O

comportamento transacional é comparado com a atividade econômica e capacidade financeira dos clientes, possibilitando a identificação de movimentações suspeitas.

A capacidade financeira dos clientes é inicialmente inferida utilizando-se uma razão entre a sua suposta capacidade de pagar contas pelo montante de dinheiro que recebe de outras contas, e a sua renda presumida, calculada como o mínimo entre a renda informada pelo cliente e a renda obtida através de *bureaus* de crédito. A informação de renda também pode ser enriquecida por meio de dados públicos (de fácil acesso para o caso de funcionários públicos, através dos chamados Portais da Transparência) e por meio de comprovação de renda quando solicitado ao cliente.

Dessa forma, a divisão entre o montante movimentado pelo cliente em um intervalo de tempo (no caso, o montante mensal médio que entra na conta do cliente) e a renda presumida é o índice utilizado para medir quantitativamente a distância do cliente de sua capacidade financeira. A equação abaixo ilustra essa relação.

$$M_{cf} = \frac{m}{\min(r_1, r_2)}$$

$M_{cf}$  = Múltiplo de capacidade financeira  
 $m$  = Média do montante de *transfer-ins* dos 6 últimos meses (em R\$)  
 $r_1$  = Renda mensal obtida do *bureau* de crédito (em R\$)  
 $r_2$  = Renda informada pelo cliente na criação da conta (em R\$)

A variável de Múltiplo de Capacidade Financeira seria utilizada como valor de corte para os alertas mínimos: somente apareceriam casos com  $M_{cf} \geq 1$ . Isto evitaria que aparecessem nos alertas aqueles clientes que estivessem movimentando grandes quantidades, mas que tivessem capacidade financeira alta o suficiente para justificar essas movimentações.

Para cada variável de influência de risco de PLD, mensurou-se: 1) o nível de gravidade da variável como a probabilidade de a variável gerar uma investigação detalhada pelos analistas de PLD, e 2) a probabilidade, medida através da frequência de ocorrência, deste evento de alto risco se consolidar. A fim de facilitar a visualização do nível de risco, as medidas foram mapeadas em baixo, médio e alto, conforme os quadros a seguir.

**Quadro 8 - Mapa de nível de gravidade**

<b>Faixa de conversão da análise para tratativa</b>	<b>Nível de Gravidade</b>
0-30%	Baixo
31-70%	Médio
70%+	Alto

Fonte: Elaborado pelo Autor

**Quadro 9 - Mapa de Probabilidade de ocorrência**

<b>Número de casos mensais</b>	<b>Probabilidade</b>
0-30	Baixo
31-100	Médio
100+	Alto

Fonte: Elaborado pelo Autor

Com o intuito de ilustrar a elaboração do processo de avaliação de nível de gravidade e probabilidade realizado para cada um dos alertas, é apresentado abaixo um exemplo de aplicação da metodologia com o alerta de pré-pagamento.

#### **Exemplo : Pré-pagamento em montantes acima da capacidade financeira**

Os pré-pagamentos no cartão de crédito são geralmente realizados com o intuito de permitir ao cliente gastar no cartão mais do que seu limite pré-definido. Desta forma, ao monitorar se um cliente está realizando pré-pagamentos em níveis acima de sua capacidade financeira, seria possível identificar suspeitos que tivessem obtido dinheiro por meios não-convencionais e estivessem realizando gastos elevados, retornando este dinheiro de volta à economia real.

O nível de gravidade deste alerta pode ser considerado médio, uma vez que é possível identificar segmentos de clientes, em faixas de valores mais expressivos, que convertem até 40% dos casos em tratativas, como pode ser observado na Figura 1.


Nota-se um aumento na conversão para tratativas a partir da faixa de R\$40.000,00 mensais de pré-pagamento. O número de casos analisados a partir desse valor corresponde a



cerca de 10% do total de casos analisados de cartão de crédito, e deve permanecer entre 30 e 100 casos mensais, o que configura um evento de média probabilidade.

Vale notar que este evento possui certa intersecção com demais categorias de riscos de cartão de crédito (como "Gastos acima da capacidade financeira"), uma vez que é de certa forma esperado que um cliente com gastos expressivos no cartão de crédito esteja operando acima de seu limite pré-estabelecido, e que portanto, deve ter realizado pré-pagamentos anteriormente.

**Gráfico 8 - Taxas de conversão para tratativas no alerta de pré-pagamento**



Fonte: Elaborado pelo Autor

Seguindo a lógica dos exemplos apresentados, para cada um dos alertas, foi feita uma análise semelhante de conversão, e valores-referência foram especificados. Como na própria análise foram conferidos não somente o risco dos alertas, como também o número de casos que seriam gerados, foi possível traçar uma estimativa de dimensionamento de casos para todos os alertas. Os valores-referência foram alterados por um múltiplo, por questões de confidencialidade.

**Quadro 10 - Mapa de Probabilidade de ocorrência**

<b>Alerta</b>	<b>Nível de Gravidade</b>	<b>Probabilidade</b>	<b>Descrição da métrica</b>	<b>Valor-referência</b>
Pré-pagamento em montantes acima da capacidade financeira	Médio	Médio	Montante mensal de pré-pagamento	$\geq$ R\$30.000,00
Concentração de compras em um mesmo estabelecimento com montantes acima da capacidade financeira	Baixo	Baixo	Montante mensal de gastos em um só estabelecimento	$\geq$ R\$4.000,00
Desvios no padrão de consumo	Baixo	Baixo	Montante mensal de gastos após inatividade	$\geq$ R\$8.000,00
Gastos acima da capacidade financeira	Médio	Médio	Montante mensal de gastos acima de $Mcf=2,5$	$\geq$ R\$30.000,00
Pedidos frequentes de aumento de limite	Baixo	Baixo	Número de pedidos de aumento de limite	$\geq$ 40
Compra em países de alto risco ou de jurisdição monitorada pelo GAFI	Baixo	Baixo	Montante mensal de gastos em países do GAFI	$\geq$ R\$10.000,00
Contestação de compras após o pagamento da fatura	Baixo	Baixo	Montante mensal em estornos requisitados	$\geq$ R\$5.000,00

Fonte: Elaborado pelo Autor

Concluído o estudo de dimensionamento do modelo de alarmes mínimos para cada uma das categorias elaboradas acima, foi possível ter uma visão mais clara de quais alertas deveriam ser priorizados pela equipe. Após os analistas terminarem de investigar os casos do mês oriundos dos alarmes mínimos, que estariam ordenados em sequência decrescente de cada um dos valores-referência, eles dedicariam sua capacidade operacional restante para investigar casos oriundos do modelo de *machine learning*.

Cada analista de PLD seria responsável por um ou dois tipos de alertas mínimos em um determinado mês, e haveria um sistema de rodízio para os meses subsequentes, com o intuito de evitar repetição no trabalho. As regras descritas acima foram programadas em um *dataset series* que seria integrado ao *data warehouse* da *Fintech X*, e que exibiria diariamente os casos que deveriam ser investigados de forma automática.

#### 4.2.3.2 Criação do modelo de machine learning

Para a criação do modelo de *machine learning*, o Autor decidiu seguir o processo de criação de modelos padronizado da *Fintech X*, porém com algumas leves modificações.

Em primeiro lugar, dentre os vários modelos que podem ser escolhidos e testados, geralmente há um conflito entre performance e interpretabilidade. Modelos simples, como uma regressão linear, são extremamente fáceis de serem interpretados por outras pessoas, porém podem apresentar uma performance ruim, ou seja, precisão do resultado aquém do esperado, caso os dados utilizados possuam padrões complexos. Por outro lado, modelos de alta complexidade, tais como redes neurais, podem aprender padrões bastante complexos e apresentar grande acurácia de previsão, entretanto, são extremamente difíceis de serem interpretados e explicados para outras pessoas. Esses modelos são conhecidos como “caixa-preta”.

Para muitos problemas de negócios, interpretabilidade não é um problema, visto que o mais importante de tudo é fazer com que o modelo acerte suas previsões. Entretanto, pelo fato de o problema em questão estar ligado a uma área extremamente regulamentada - a de Prevenção à Lavagem de Dinheiro - é provável que, caso haja uma inspeção do BACEN na *Fintech X*, seja necessário explicar minuciosamente o funcionamento dos sistemas de detecção de casos suspeitos de lavagem de dinheiro para o regulador.

O problema a ser solucionado era da natureza de classificação (prever se o suspeito era ou não um caso de alto risco de lavagem de dinheiro), e, portanto, de aprendizagem supervisionada, segundo a literatura de *machine learning*. Por definição, deveriam ser escolhidos modelos que fornecessem não somente a classificação binária do suspeito, mas também a probabilidade de ele pertencer à classe de alto risco. Essa probabilidade permitiria que os casos fossem ranqueados por risco, o que facilitaria a priorização de investigações por parte dos analistas de PLD.

Antes da escolha do modelo, partiu-se para a preparação do *dataset* de “treino” do modelo. Este *dataset* contém basicamente todos os casos já investigados no passado, com sua respectiva classificação binária (“1” se foi aberta uma tratativa para o suspeito, ou “0 se não”), bem com todas as características comportamentais do cliente, como por exemplo, média de movimentações realizadas por dia durante os últimos trinta dias, média mensal de volume de compras, dentre outros.

O *dataset* de treino é basicamente uma forma de entregar ao modelo uma série de exemplos para que ele possa “aprender” com eles quais são as características, ou *features*, mais importantes para se classificar um suspeito. Dessa forma, após passar por centenas de casos já classificados, o modelo será capaz de prever qual é a probabilidade de que o novo suspeito apresente de fato um caso de alto risco de Lavagem de Dinheiro.

A elaboração do *dataset* de treino foi realizada unindo a tabela do histórico de investigação de suspeitos com outras tabelas contendo *features* de comportamento do cliente. Esta junção foi feita utilizando a linguagem de programação Scala através de consultas à base de dados transacionais da empresa. Foram reunidas cerca de 120 *features* diferentes, que incluíam informações sobre transações, movimentações financeiras, idade do cliente, etc.


Para a criação do modelo, foi utilizada a biblioteca Scikit-learn da linguagem Python, que é *open-source* e pode ser utilizada sem custo. Uma vez com o *dataset* de treino finalizado, é possível importar modelos pré-programados da biblioteca Scikit-learn e rodar um simples comando para que o modelo desejado seja “treinado” com o *dataset* inserido.

O modelo escolhido foi a regressão logística. A razão para esta escolha foi simples: é um modelo fácil de ser interpretado, adequado para ser utilizado em problemas em que a variável dependente é binária, e utilizado dentro da *Fintech X* em problemas de diversas naturezas. Assim, com maior domínio disseminado deste conhecimento, seria fácil conseguir ajuda caso fosse necessário mudar parâmetros do modelo manualmente.

Há dois principais outputs que devem ser considerados: o ranqueamento de importância de cada *feature*, e a pontuação de performance do modelo.

Para o primeiro, foi utilizada a metodologia SHAP (*SHapley Additive exPlanations*), uma abordagem de código aberto que busca explicar quão bem cada *feature* segrega a classificação dos suspeitos. Uma *feature* que, por exemplo, apresenta valores altos nos casos em que o suspeito foi reportado ao Coaf (classificação binária igual a 1) e valores baixos no caso oposto (classificação binária igual a 0), possui altas chances de receber um *score* SHAP alto. O ranqueamento das *features* foi o seguinte:

**Gráfico 9 - Ranqueamento SHAP de *features***



Fonte: Elaborado pelo Autor

Como se pode observar, há um grande número de *features* relacionadas a gastos que explicam bem a diferença de classificação binárias - o que era esperado, uma vez que clientes que tendem a ter gastos extremos acabam possuindo alto risco de lavagem de dinheiro. O objetivo desta análise foi tentar buscar evidências de quais parâmetros deveriam ser tidos como os mais críticos para os analistas de PLD - eles não necessariamente são um bom indicador da performance do modelo, que será detalhado a seguir.

Para medir a performance do modelo, ou o seu nível de precisão, foi utilizada a métrica AUC-ROC (*Area Under the Curve - Receiver Operating Characteristic*). A curva ROC mostra o quão bem o modelo criado pode distinguir entre duas classificações (no caso, 0 ou 1). A curva possui dois parâmetros:

- Taxa de verdadeiro positivo (*True Positive Rate*), que é dada por:  

$$\text{Verdadeiros positivos} / (\text{Verdadeiros positivos} + \text{Falsos negativos})$$
- Taxa de falso positivo (*False Positive Rate*), que é dada por:


*Falsos positivos / (Falsos positivos + Verdadeiros negativos)*

Uma curva ROC traça a “True Positive Rate vs. False Positive Rate” em diferentes limiares de classificação. Assim, na tentativa de simplificar a análise da ROC, a AUC surgiu como uma maneira de resumir a curva ROC em um único valor, agregando todos os limiares da ROC, calculando a “área sob a curva”.

Uma vez que a área abaixo da curva ROC é uma fração da área de um quadrado de lado um, o seu valor está sempre entre 0 e 1. Além disso, a AUC também é numericamente igual à probabilidade de que, dados dois exemplos de classes distintas, o exemplo positivo seja ordenado primeiramente que um exemplo negativo. Em termos de performance de modelos, quanto maior o AUC, melhor.

A curva obtida, bem como o seu valor de AUC, foi o seguinte:

**Gráfico 10 – Curva ROC para o modelo implementado**



Fonte: Elaborado pelo Autor

Com um AUC *score* de aproximadamente 0.661, pode-se dizer que o modelo obteve uma pontuação razoável, porém longe de ser ideal. Para efeitos de comparação, modelos de *Machine learning* mais sofisticados da *Fintech X* costumam ter AUC *scores* superiores a 0.750. Uma possível explicação dessa pontuação abaixo da média de outros modelos é o tamanho pequeno da amostra utilizada no *dataset* de treino, de somente 1300 observações. Com menos

observações, o modelo enfrenta dificuldades de “aprender” padrões mais sofisticados nos dados.

Mesmo com uma performance ainda com espaço para melhorias, foi decidido que seria feito um teste durante três meses utilizando o modelo. Caso seu índice de precisão estivesse abaixo do sistema atual de alertas, ele teria que ser re-treinado com dados novos. Assim, foi requisitado para o time de cientistas de dados que o modelo fosse colocado em “produção”, ou seja, que ele estivesse online na infraestrutura de cloud e identificando suspeitos diariamente, sem a necessidade de executar comandos manuais.

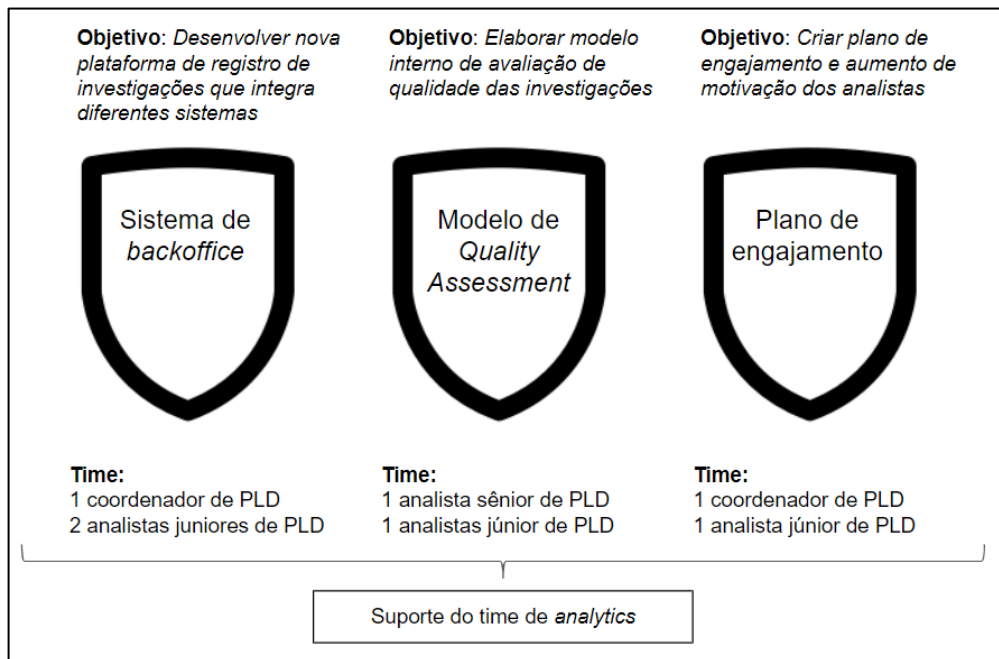
### **4.3 Objetivo 2: aumentar a produtividade dos analistas de PLD**

Como as soluções que foram priorizadas para resolver os problemas da operação (descritas em 3.7 “Priorização de soluções”) envolveriam muitos inputs dos analistas, o time de *analytics* decidiu que a forma mais otimizada de solucionar esses problemas seria através da criação de grupos paralelos de trabalho com os analistas de PLD. Dessa forma, cada uma das soluções seria implementada com a ajuda de alguns analistas que estariam participando como um projeto secundário - conceito introduzido no capítulo “3.3.1 Modo de operação atual”. O time de *analytics*, portanto, teria um papel de “gestor” desses vários sub-projetos, acompanhando o seu desenvolvimento e oferecendo suporte até a conclusão de cada um deles.

Dessa forma, o time de *analytics* decidiu então criar os grupos de trabalho, e recrutou analistas de PLD, baseados em seus interesses, nas iniciativas que seriam tomadas. Cada grupo de trabalho, apelidado de “*Shield*”, seria uma unidade autônoma, guiada por um analista de PLD mais sênior, que seria responsável pelos resultados dos projetos.

A figura a seguir resume os *shields* e suas atribuições:

**Figura 18 - Sistema de trabalho em *Shields***



Fonte: Elaborado pelo Autor

Vale notar que o Autor do Trabalho de Formatura se envolveu no desenho dessas três iniciativas e na elaboração do planejamento de atividades, e realizou reuniões com os analistas sêniores de PLD que eram os líderes de cada uma das iniciativas, para verificar o andamento das tarefas e discutir sobre possíveis pontos de melhorias. Nota-se que não existe uma relação de subordinação do time de operações ao time de *analytics* neste caso. Embora o último tenha ajudado o primeiro com o planejamento de tarefas, é o próprio time de operações que deveria assegurar o cumprimento das atividades planejadas, e o time de *analytics* atuou como suporte tático e estratégico.

Na seção seguinte, serão apresentados os projetos desenvolvidos por cada um dos *shields* em maior detalhe.

### 4.3.1 Detalhamento da solução

#### 4.3.1.1 Sistema de backoffice

O modelo utilizado para registro das investigações pelos analistas de PLD era, de certa forma, bastante rudimentar. Utilizavam-se planilhas no software Google Sheets, que permitiam



que todos do time visualizassem os mesmos arquivos. Cada linha da planilha correspondia a um suspeito diferente, e cada aba da planilha se referia a um alerta. Desta forma, os analistas se dividiam para que cada um ficasse responsável por um alerta diferente, e assim, analisavam os casos seguindo a ordem de risco determinada pelos *notebooks* que identificavam os casos suspeitos.

O processo, entretanto, era cheio de problemas, como ilustrou o capítulo “3.4 Problemas e desafios identificados”. A maioria deles se concentrava na possibilidade incorrida de se realizar erros operacionais, e na existência de muitas planilhas diferentes para acompanhar, o que gerava ineficiência na realização do trabalho. Além disso, há uma questão de privacidade dos dados, uma vez que informações contidas nas planilhas podem ser facilmente compartilhadas com pessoas de fora do time, o que se torna uma questão de conformidade regulatória: no caso de uma inspeção do BACEN na instituição financeira, o controle por planilhas poderia parecer frágil e inadequado para uma empresa com o tamanho da *Fintech X*.

Notou-se rapidamente que a solução ideal para esta situação era trocar a plataforma, e deixar de usar planilhas para o acompanhamento das investigações. Isso exigiria a criação de um serviço - como são denominados os programas ou aplicações desenvolvidas internamente pelo time de engenheiros de software. Entretanto, criar um serviço não é uma tarefa trivial, pois devido à alta demanda interna por diversos projetos que envolvem o grupo de engenharia, o tempo e os recursos humanos deste time necessários para um projeto acabam sendo disputados.

Dessa forma, foi elaborada uma proposta minuciosa da necessidade de se implementar um serviço de PLD, a ser apresentado para o *squad* de *Defense Engineering*. Como este time reúne desenvolvedores alocados especificamente para a construção de plataformas e serviços de Defesa da *Fintech X*, a chance de o time de PLD receber uma elevada prioridade com este projeto seria maior.

O *shield* deste projeto reunia um coordenador e duas analistas de PLD, que ficariam encarregadas de atuar na definição de funcionalidades, no direcionamento da criação da plataforma por meio de feedbacks e no treinamento dos demais analistas para uso da ferramenta.

A proposta do projeto foi formalizada em um documento pelo *shield* juntamente com o time de *analytics*, e em conjunto com uma *Product Manager* (PM), ou Gerente de Produto, do time de *Defense Engineering*. Ela reunia informações sobre os requisitos do produto e sua integração com demais serviços da *Fintech X*.

De forma geral, o serviço funcionaria da seguinte maneira: os alarmes mínimos programados em *dataset series* e o modelo de *machine learning*, ambos armazenados no *data warehouse* da *Fintech X*, gerariam os casos mais suspeitos para serem investigados em cada

mês. Esses casos iriam para o novo sistema de *backoffice* a ser desenvolvido, apelidado internamente de “Detetive”, que aplicaria uma lógica simples - se o suspeito já tivesse sido investigado nos últimos 6 meses, ele seria descartado, se não, ele seguiria para a etapa de distribuição para os analistas de PLD.

Quando os analistas entrassem no sistema, ao invés de terem que buscar os suspeitos nas tabelas geradas por *notebooks* e registrar as informações em planilhas do Google Sheets, eles já teriam um caso suspeito à espera, que fora enviado automaticamente pelo Detetive. Nesta tela, que seria semelhante ao sistema de atendimento ao cliente existente na *Fintech X*, seriam reunidas as principais informações cadastrais sobre o suspeito, o alerta programado que gerou sua aparição, e campos em aberto para que o analista pudesse registrar sua investigação.

Após a avaliação do caso, o analista poderia tomar uma das quatro ações abaixo:

**(i) Registrar como baixo risco:** o caso seria marcado como resolvido, e o suspeito sairia da fila de casos a serem investigados. Caso o analista julgasse necessário, poderia ser aberto um alerta de monitoramento do cliente, para que ele voltasse à fila de *jobs* depois de um número de dias determinado.

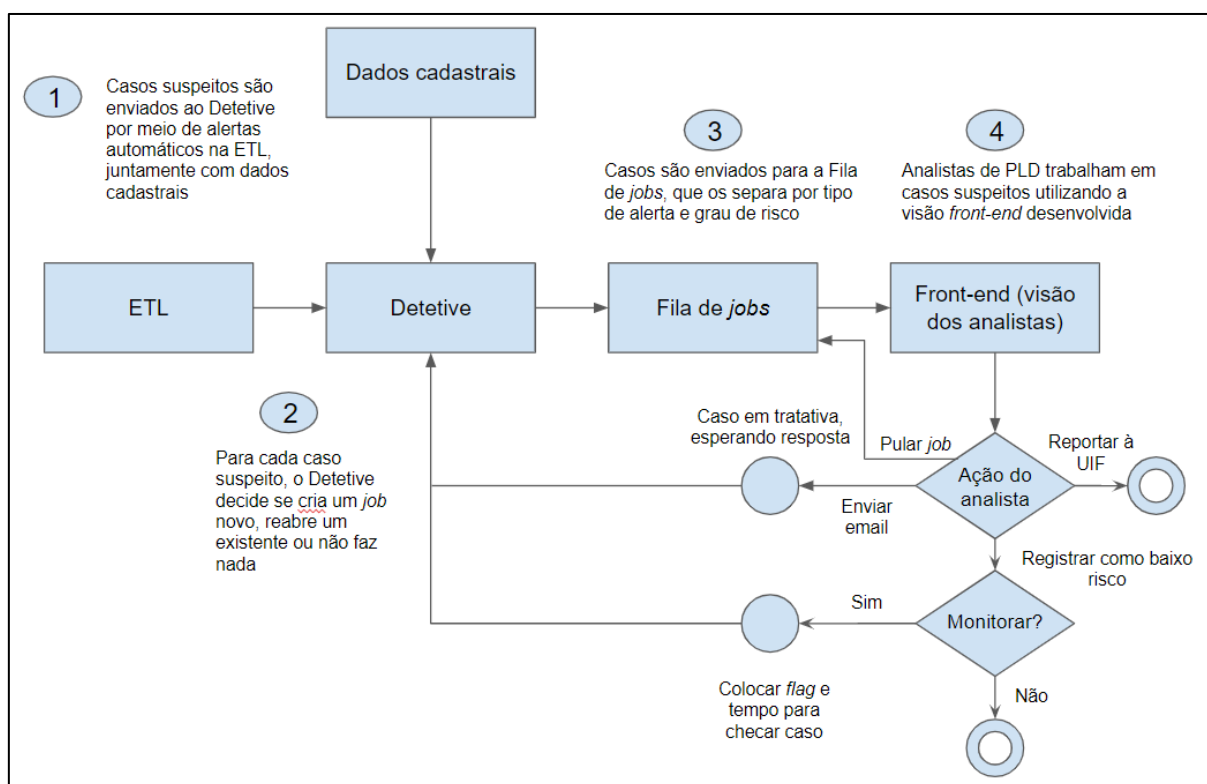
**(ii) Abrir tratativa:** em caso de leve suspeita de lavagem de dinheiro, seria enviada uma mensagem automática por e-mail requisitando um documento que comprovasse a capacidade financeira do cliente, como comprovante de renda ou declaração de Imposto de Renda. Enquanto o cliente não respondesse, o caso ficaria em aberto. Seria dado um limite de 15 dias para que o cliente apresentasse comprovantes, e caso não o fizesse, poderia ter sua conta e cartão cancelados.

**(iii) Reportar ao Coaf:** se há indícios claros de lavagem de dinheiro, o suspeito seria reportado ao Coaf, marcado como provável lavador de dinheiro e seria comunicado ao cliente o cancelamento de sua conta, havendo um prazo de 30 dias para que ele pagasse sua última fatura (se existente) e retirasse todo o dinheiro de sua conta.

**(iv) Pular o job:** se o analista não acredita ser capaz de julgar o caso com propriedade, ele pode escolher fazer o caso voltar para a fila de *jobs* para que outro analista o assuma.

A lógica de funcionamento do novo serviço pode ser ilustrada pelo diagrama a seguir:


**Figura 19 - Diagrama com lógica do serviço de *backoffice***



Fonte: Elaborado pelo Autor

Uma vez definidos os requisitos do projeto e a lógica de funcionamento, o time de *analytics* se reuniu novamente com a *Product Manager* e com o *shield*. A PM seria responsável por coordenar os esforços dos engenheiros de *Defense Engineering*, e o time de *analytics* seria responsável por garantir a integração do novo sistema com o modelo de geração de alertas. Houve mais uma sessão de *brainstorming* para a definição de todas as funcionalidades que deveriam estar presentes no *front-end*, e que teve como resultado um protótipo da tela na visão dos analistas de PLD:

**Figura 20 - Mock-up ilustrativo da tela do serviço**



Fonte: Fotografado pelo Autor

Dessa forma, com todos as partes interessadas alinhadas, cada frente do projeto deveria se organizar de modo a garantir que seus entregáveis fossem completados em tempo hábil.

Quanto à parte de dados, o tempo do projeto de criação do sistema se alinhou de forma sinérgica com o desejo do time de implementar o sistema de alarmes mínimos com o modelo de *machine learning*. Como a geração dos alertas já seria transferida dos *notebooks* para os *datasets* que rodariam de forma automática na ETL, bastaria realizar a integração do sistema com esses *datasets*, de modo que os casos suspeitos que surgissem fossem oriundos da nova lógica de alarmes mínimos e do modelo de *machine learning*.

Ao longo do projeto, conforme as telas do novo sistema eram produzidas, o *shield* do novo sistema realizava reuniões para passar feedbacks e sugerir alterações. A dinâmica funcionou de forma exemplar, com os membros do *shield* engajados e interessados com o desenvolvimento do novo sistema, uma vez que representaria um grande ganho de qualidade e profissionalismo no processo de investigações, e os outros *stakeholders* do projeto também estavam animados com o impacto no ganho de eficiência e escalabilidade que o sistema traria.

### 4.3.1.2 Modelo de *Quality Assessment*

Um grande problema levantado pelos analistas de PLD era que a qualidade das investigações possuía um nível de variabilidade alto, dependendo do analista que a realizasse. Não havia métricas internas objetivas que medissem a qualidade dos reportes, e segundo as entrevistas com os analistas, ao ler os comentários e documentação escritos por seus colegas, alguns deles tinham uma impressão subjetiva de que nem todas as análises apresentavam o mesmo padrão de qualidade.

O único indicador de qualidade das investigações eram as notas do Coaf atribuídas aos reportes que eram enviados. Para cada reporte, a instituição atribuía uma nota de 1 a 4, sendo as notas avaliadas pela seguinte escala:

**Quadro 11 – Escala de avaliação dos reportes pelo Coaf**

Nota	Avaliação
1	Comunicação apresenta problema na forma e no conteúdo.
2	Comunicação apresenta problema apenas no conteúdo
3	Comunicação apresenta problema apenas na forma
4	Comunicação não apresenta problema

Fonte: *website* do Coaf

Entretanto, não havia um feedback mais detalhado do Coaf explicitando quais exatamente seriam os problemas encontrados nos relatórios. Portanto, para que a instituição financeira melhorasse a nota média de avaliações, seria necessário calibrar o padrão dos reportes para que estes se encaixassem melhor nos critérios que estavam sendo avaliados pelo Coaf. Para tal, a melhor maneira seria implementar um processo sistemático de avaliação interna da qualidade dos reportes, e após alguns meses de devolutivas do Coaf, os analistas de PLD poderiam rebalancear esse processo e testar novos modelos de formatação e conteúdo dos reportes para maximizar as notas de avaliação recebidas.

Verificou-se nitidamente, portanto, que havia a necessidade de:

- (i) Criar um modelo de avaliação objetivo para as investigações dos analistas de PLD;

(ii) Alinhar o modelo com o resto da equipe e instaurar uma cultura de verificação de qualidade das investigações.

Diferentemente do projeto anterior, que de fato exigia um esforço de execução por parte do time de *analytics* na integração do sistema com os alertas automatizados, neste projeto o *shield* executaria a maior parte dos processos, e o time de *analytics* participaria no desenho da solução e no suporte para instauração de uma cultura voltada à qualidade das investigações, caso os analistas do *shield* necessitassem de ajuda.

Segundo Slack (1997), qualidade é a consistente conformidade com as expectativas dos consumidores. Contudo, basear a definição de qualidade em expectativas gera um conflito, dado que as expectativas variam entre os usuários, logo, as percepções também variam. Nos serviços, essa variação está relacionada ao fato de serem intangíveis, o que leva os usuários a terem percepções diferentes em diversos momentos.

Pode-se considerar que a entrega de reportes ao Coaf é um serviço que está sendo prestado e que é avaliado segundo alguns parâmetros objetivos pela instituição que os consome. O único empecilho é que tais parâmetros não são amplamente divulgados pelo Coaf, e, portanto, a questão da percepção do “cliente” acaba se tornando uma variável obscura na equação.

Dessa forma, o planejamento da criação do modelo de verificação da qualidade deve ser iniciado com algumas premissas sobre o que exatamente o reporte deve conter. As matrizes a seguir, realizadas pelo *shield* em conjunto com o time de *analytics*, listam os requisitos de um reporte de qualidade, na percepção do time, e o grau de importância que cada um deles deveria ter.

Foram atribuídos pesos de descontos para que, no final, cada etapa do reporte de um analista de PLD pudesse ser avaliado segundo a metodologia elaborada, recebendo uma nota de 50 a 100. A primeira etapa de "KYC" (*Know-Your-Customer*, ou "Conheça seu cliente"), consiste no preenchimento das informações básicas do cliente investigado pelo analista de PLD, e é parte crucial para a correta avaliação do risco que o suspeito impõe. Em seguida, parte-se para a Tratativa, que somente ocorre quando se percebe algum risco de Lavagem de Dinheiro por parte do suspeito, e é dependente da reciprocidade na comunicação entre o suspeito e o analista. Por fim, caso haja de fato um risco considerável de Lavagem de Dinheiro no caso analisado, é elaborado o reporte final ao Coaf.

A decisão de separar a avaliação da investigação em 3 partes se deve ao fato de que nem sempre uma investigação iniciada irá terminar em um reporte ao Coaf. Portanto, para não prejudicar analistas que receberam casos pouco suspeitos para investigar, optou-se por fazer

uma avaliação separada. A nota final da investigação seria composta pela média aritmética das notas obtidas em cada uma das etapas.

Escolheu-se utilizar um método de desconto por itens ausentes, e não de pontuação por itens presentes, porque partiu-se da hipótese de que uma penalidade na pontuação do reporte é mais impactante para a percepção do analista quanto ao seu próprio trabalho do que acréscimos incrementais em sua pontuação caso ele estivesse realizando tudo de maneira correta. Dessa forma, esperava-se que os analistas de PLD ficassem mais atentos a possíveis deslizes em seu trabalho.

Cada etapa teria uma pontuação inicial de 100 pontos, e que poderia ser reduzida para 50 pontos dependendo dos descontos. A nota final da investigação seria a média aritmética das notas de cada uma das etapas realizadas pelo analista. Se a segunda e terceira etapa não fossem realizadas, elas não entrariam para o cálculo da média. Os quadros abaixo detalham com maior profundidade os critérios utilizados para os descontos em cada etapa.

**Quadro 12 - Escala de avaliação da etapa de KYC**

<b>Etapa 1: KYC (<i>Know Your Customer</i>)</b>		
<b>Descrição da pergunta de avaliação</b>	<b>Pontos de desconto (se ausente)</b>	<b>Gravidade</b>
Foi feito/atualizado o KYC em sua completude?	30	Gravíssimo
Mediante KYC preenchido, foi informado o risco do cliente na coluna específica?	5	Leve
As informações encontradas foram explicadas/inseridas de maneira clara?	5	Leve
O risco do KYC pode ser evidenciado mediante informações registradas?	10	médio
<i>Desconto máximo</i>	50	

Fonte: elaborado pelo Autor

**Quadro 13 - Escala de avaliação da etapa de Abertura de Tratativa**

<b>Etapa 2: Abertura de Tratativa</b>		
<b>Descrição da pergunta de avaliação</b>	<b>Pontos de desconto (se ausente)</b>	<b>Gravidade</b>
Incluiu e/ou retirou as <i>tags</i> corretamente?	5	Leve
Atualizou o KYC/Tratativa assim que recebeu o comprovante de renda (se necessário)?	10	Médio
Tratativa é passível de reporte e foi reportada?	30	Gravíssimo
Enviou a comunicação correta?	5	Leve
<i>Desconto máximo</i>	50	

Fonte: elaborado pelo Autor

**Quadro 14 - Escala de avaliação da etapa de Abertura de Tratativa**

<b>Etapa 3: Envio de reporte ao Coaf</b>		
<b>Descrição da pergunta de avaliação</b>	<b>Pontos de desconto (se ausente)</b>	<b>Gravidade</b>
O texto foi revisado antes do envio do reporte? (ortografia, coesão, tom de voz, etc)	20	Grave
Há informações que revelam ao COAF que o KYC foi realizado? (Profissão do cliente, renda, colisões, mídias negativas, etc).	20	Grave
O reporte foi feito dentro do prazo? (40 dias da abertura da tratativa ou até o 5º dia útil do mês seguinte)	10	Médio
<i>Desconto máximo</i>	50	

Fonte: elaborado pelo Autor

Para a avaliação das análises, ao fim de cada mês, seriam retiradas como amostras três investigações feitas por cada analista. Dessa forma, seria feita uma avaliação completa de cada uma dessas três investigações, e a nota final do analista naquele mês seria a média aritmética entre as suas três notas. A escolha pelo número de três amostras foi puramente por conta da capacidade operacional de avaliação disponível. Sentia-se que somente uma ou duas amostras

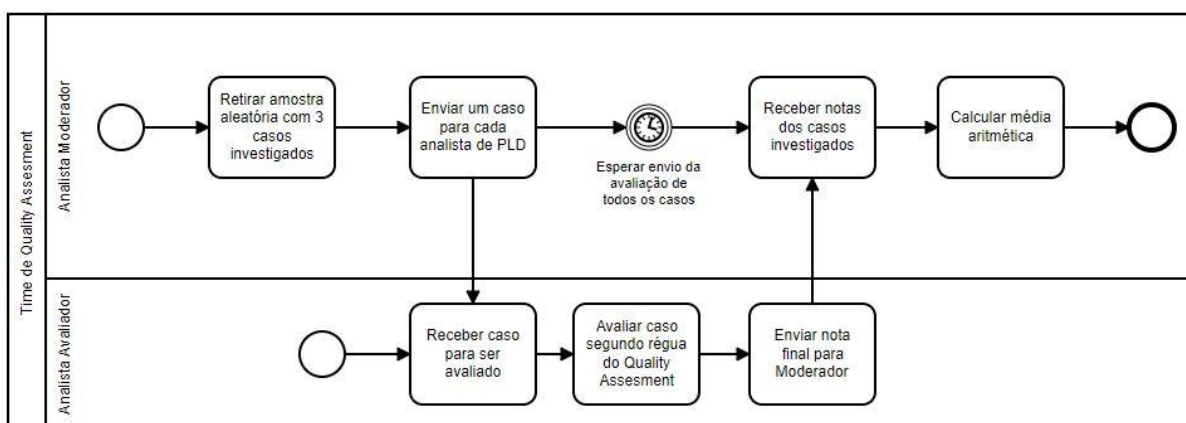


por analista seria pouco para se obter uma conclusão precisa do analista, e mais do que três amostras demandariam muito trabalho de avaliação por parte dos analistas do *shield*.

As amostras a serem retiradas seriam aleatórias (com a única condição de que houvessem sido realizadas naquele mês), e atribuídas aos membros do *shield* de forma também aleatória. Além disso, as investigações seriam anonimizadas, de forma que não se poderia saber o autor da análise, e, portanto, evitaria-se eventual parcialidade na atribuição das notas. Para garantir que um membro do *shield* não recebesse um caso de sua autoria para analisar, ficou acordado que a atribuição de casos seria feita por um membro do time de *analytics*, que não participaria da rodada de avaliações. A aleatorização de retirada da amostra e a atribuição a um membro do *shield* seria feita em uma simples planilha do software Google Sheets.

Uma vez que a rodada de avaliações mensal fosse concluída pelos membros do *shield* de *Quality Assessment*, os resultados gerais seriam divulgados na reunião com o *squad* de PLD inteiro. Seriam compartilhadas as métricas referentes a cada uma das categorias, mostrando como estaria o desempenho do *squad* em cada uma das categorias citadas acima, de modo que o *shield* poderia dar orientações mais específicas de como melhorar a qualidade geral dos reportes. Entretanto, não seriam mostradas as métricas individuais para evitar demasiada exposição individual, e os resultados mais detalhados para cada analista seriam enviados logo após a reunião de forma individual. O fluxograma a seguir ilustra como funcionaria o processo como um todo:

**Figura 21 - Fluxograma de avaliação do *Quality Assessment* em BPMN**



Fonte: Elaborado pelo Autor

O *modus operandi* descrito foi validado com todos os membros do *squad* antes que fosse iniciado, e foi recebido positivamente. Todos os membros presentes do *squad* concordaram que a retirada de amostras aleatórias faria com que eles tivessem que prestar atenção em todas as

investigações que realizassem, o que provavelmente provocaria um aumento geral na qualidade das investigações.

Como citado anteriormente, a metodologia foi criada com o intuito de elevar as notas médias de reportes atribuídas pelo Coaf. Dessa forma, este projeto deveria ser constantemente aprimorado - caso fosse observado uma discrepância grande entre as notas atribuídas internamente e as do Coaf, os pesos e os critérios teriam de ser revistos.

#### **4.3.1.3 Plano de engajamento**

O plano de engajamento dos funcionários nada mais é que uma medida para acompanhar e melhorar a satisfação e a motivação dos analistas de PLD com o trabalho sendo exercido. Como em grande parte do dia o trabalho acaba tendo um caráter mais mecânico, com procedimentos iguais a serem seguidos, um serviço altamente individualizado, é necessário que os funcionários não se sintam desmotivados com o caráter do trabalho e que sejam tomadas medidas para aumentar seu engajamento e garantir que os níveis de produtividade não caiam.

A elaboração do plano reuniu o Autor do Trabalho de Formatura e os analistas do *shield* de engajamento. No entendimento dos presentes, havia duas principais medidas que seriam responsáveis por cumprir o objetivo de manter um engajamento e motivação saudáveis do *squad* de PLD:

- (i) um processo sistemático de avaliação e monitoramento dessas dimensões com todos os membros do *squad*;
- (ii) um conjunto de medidas para efetivamente melhorar as dimensões que estiverem inadequadas.

Evidentemente, as medidas de melhoria só poderiam ser implementadas após serem conhecidos os principais pontos de atenção. Portanto, o primeiro passo foi elaborar o questionário de avaliação de engajamento a ser aplicado, distribuí-lo aos membros do *squad* e aguardar as respostas. O formulário foi elaborado com base em frases prontas que o membro do time deveria avaliar segundo uma escala Likert de quatro pontos (em sua maioria). Ele foi distribuído eletronicamente pela plataforma *Google Forms*, e foi dado o prazo de uma semana para que ele fosse completado. A estrutura do formulário foi a seguinte:

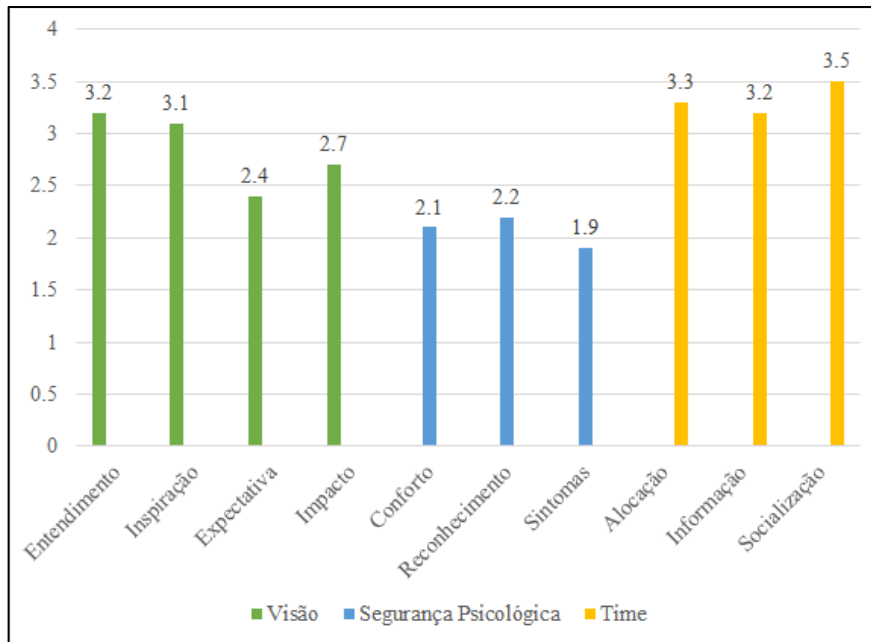
**Quadro 15 – Afirmações de avaliação do formulário de engajamento**

<b>Pergunta/Afirmação</b>	<b>Palavra-chave</b>	<b>Escala de avaliação</b>
“Eu entendo nossa visão e acredito que estamos trabalhando nas iniciativas mais importantes para alcançá-la.”	Entendimento	1 (Nunca) a 4 (Sempre)
“Eu me sinto inspirado e motivado com os desafios do squad.”	Inspiração	1 (Nunca) a 4 (Sempre)
“Eu sei o que é esperado do meu trabalho.”	Expectativa	1 (Nunca) a 4 (Sempre)
“Eu sinto o impacto do meu trabalho nos resultados do squad”	Impacto	1 (Nunca) a 4 (Sempre)
“Eu me sinto confortável durante reuniões para fazer perguntas, sugestões e/ou expor meu ponto de vista.”	Conforto	1 (Nunca) a 4 (Sempre)
“Eu sinto que meu trabalho é reconhecido pelo time.”	Reconhecimento	1 (Nunca) a 4 (Sempre)
“Eu raramente sinto (mais que 1x por semana) pelo menos 1 dos seguintes sintomas: exaustão emocional, despersonalização (apatia, indiferença), e/ou falta de auto-apreciação (sentimento de fracasso, culpa ou incompetência).”	Sintomas	1 (Discordo totalmente) a 4 (Concordo totalmente)
“Eu me sinto alocado na oportunidade que me permite ser a melhor versão de mim mesmo.”	Alocação	1 (Nunca) a 4 (Sempre)
“Eu estou sempre informado sobre as mudanças e notícias importantes que impactam nosso time.”	Informação	1 (Nunca) a 4 (Sempre)
“Há momentos o suficiente para se ter divertir e socializar com o resto do time.”	Socialização	1 (Nunca) a 4 (Sempre)

Fonte: elaborado pelo Autor

O resultado das respostas foi o seguinte:

**Gráfico 11 - Média de avaliações por categoria do Formulário de Engajamento**



Fonte: Elaborado pelo Autor

Como é possível observar das respostas, a nota média na componente de “Segurança psicológica” foi a menor dentre as apresentadas, seguida pela de “Visão” e a de “Time”. Para cada uma das dimensões apresentadas foram elaboradas hipóteses sobre os problemas existentes, e planos de ação distintos. O processo de elaboração da hipótese e dos planos de ação foram abordados em uma segunda reunião com o time de *analytics* e o *shield* de Engajamento.

A metodologia de criação das hipóteses e dos planos de ação foi a seguinte: em um primeiro momento, todos os presentes teriam até 10 minutos para escrever em *post-its* algumas hipóteses de quais seriam as causas-raiz de cada um dos pontos mal avaliados. Por exemplo, para a questão de “Segurança psicológica”, poderia ser escrito que “os membros do *squad* se sentem desmotivados porque não há um plano de carreira bem-definido”. A ideia é que nesses 10 minutos fossem gerados o maior número possível de ideias, sem que houvesse filtros ou julgamentos.

Em seguida, haveria uma rodada de discussão, no qual cada membro participante leria as suas hipóteses e colocaria os “post-its” na parede. Caso houvesse hipóteses muito semelhantes já colocadas por outros membros, os post-its seriam agrupados fisicamente, para facilitar a visualização dos grupos de hipóteses.

Por fim, com as hipóteses lidas e agrupadas, as equipes escolheriam quais hipóteses de causas-raiz eram as mais críticas, ou seja, que diziam respeito às dimensões pior avaliadas. A ideia é que, se essas causas-raiz fossem atacadas, haveria a maior diferença possível em termos de aumento da nota na métrica avaliada. Cada membro participante da reunião poderia distribuir até 3 pontos entre os grupos de hipóteses para indicar quais seriam os problemas que, em sua opinião, deveriam ser atacados com maior prioridade.

Ao final da dinâmica, foram escolhidas as três hipóteses mais críticas, e foram registrados planos de ação específicos para cada um deles. As três hipóteses mais votadas, bem como os seus planos de ação, estão descritas a seguir:

**Hipótese 1: Os analistas não possuem uma visão clara do propósito de seu trabalho porque falta contexto e integração com o mercado de PLD.**

Os analistas de PLD da *Fintech X* são todos ex-funcionários de Atendimento da empresa, que prestaram o processo seletivo interno para se tornarem analistas de PLD, e foram aprovados no processo. Desta maneira, praticamente todo o conhecimento que eles adquiriram vieram dos especialistas de Compliance da empresa. Havia, entretanto, uma sensação de desconexão com demais profissionais do mercado de PLD e as melhores práticas vigentes.

O plano de ação para solucionar este problema consistia em duas etapas: a primeira seria selecionar e estimular analistas para obterem a Certificação Profissional em Prevenção à Lavagem de Dinheiro e ao Financiamento do Terrorismo, a CPLD-FT, concedida pelo IPLD - Instituto de Profissionais de Prevenção à Lavagem de Dinheiro - e a segunda seria buscar a contratação de um *squad* lead com anos de experiência de PLD em outra instituição financeira, tendo em vista que um profissional com este perfil ainda não existia dentro da *Fintech X*.

Essas medidas auxiliariam o time a se manterem mais atualizados com os acontecimentos e práticas do mercado, e a se inserirem de forma mais relevante neste ecossistema em que a troca de informações de fato beneficia a integridade do Sistema Financeiro Nacional. A primeira medida poderia ser facilmente conduzida pelo *shield* de engajamento, enquanto a segunda exigiria um auxílio do time de Recursos Humanos da empresa para a busca e contratação deste profissional.

**Hipótese 2: Os analistas não são reconhecidos o suficiente pelos seus trabalhos porque não há um processo formal de reconhecimento de bom trabalho ou iniciativas paralelas.**

Até o momento, de fato, não havia mecanismos claros de recompensa ou reconhecimento pelo trabalho realizado pelos analistas, e isto se traduzia em uma queda generalizada de motivação da equipe de operações.

O plano de ação elaborado consistia de três medidas simples: a primeira seria separar metade do tempo das reuniões semanais da equipe para que um membro apresentasse algum material sobre um trabalho que realizou, ou um tema que acha relevante compartilhar com os demais. Isso auxiliaria no desenvolvimento pessoal de quem faria a apresentação, bem como aumentaria sua motivação dentro do ambiente de trabalho, uma vez que ele teria uma oportunidade de maior exposição aos seus pares e líderes.

A segunda medida consistia em estimular o sentimento de reconhecimento entre os membros da equipe por meio de um ritual já praticado em outros *squads* da empresa, denominado Round de Reconhecimento. A ideia por trás do ritual era que quinzenalmente o time reservasse um horário para se reunir de pé na própria área; em seguida, seria entregue um bombom para cada participante, e cada um teria um momento para reconhecer o trabalho de outra pessoa do time e lhe entregar o seu doce. A medida tem como objetivo estimular o reconhecimento interno e o clima de cooperação da equipe de forma simbólica.

Por fim, a terceira medida consistia na elaboração de um plano de remuneração variável de acordo com a performance de cada analista. Para esta ação, o *shield* consultaria o time de Recursos Humanos da empresa para auxiliá-los no desenho dessa medida.

Todas as medidas poderiam ser executadas pelo *shield* de forma imediata. Para o Round de Reconhecimento, a equipe teria acesso ao orçamento que a *Fintech X* disponibiliza para despesas com rituais e integrações de times.

### **Hipótese 3: Os analistas se sentem desmotivados porque falta capacitação técnica em análise e manipulação de dados, que auxiliariam nas investigações.**

Em diversos momentos das investigações, os analistas devem consultar os dados dos suspeitos no sistema de *backoffice* da empresa, que mostra uma visão consolidada dos clientes, com suas informações pessoais, transações e movimentações financeiras. Entretanto, muitas vezes é necessário consultar dados diretamente da ETL para se criar visões personalizadas, como por exemplo, qual é a porcentagem das compras que um cliente está realizando em um determinado lojista. Para isso, é necessário ter conhecimentos básicos de consulta e análise de dados.

Para sanar este problema, o plano de ação desenvolvido foi criar um programa continuado de capacitação em análise de dados utilizando SQL e Excel. Os treinamentos seriam dados pelo

time de *analytics*, e o *shield* seria responsável por organizar a parte logística, como agendamento de salas e recolhimento de feedbacks dos participantes. A ementa dos treinamentos, contendo os tópicos mais importantes e úteis para a operação de PLD, seriam escolhidos pelo time de *analytics*.

Esta iniciativa, embora exija maior dedicação do time de *analytics* em comparação com o *shield*, se encontra bastante alinhada com a estratégia da *Fintech X* de ser orientada a dados e estimular todos os seus funcionários a utilizarem dados para embasar suas decisões. O empoderamento de funcionários como os analistas de PLD aumentaria o seu desenvolvimento enquanto profissionais e poderia melhorar a sua satisfação pessoal com o trabalho.

O quadro a seguir mostra um resumo de todas as hipóteses levantadas e os planos de ação que seriam conduzidos pelo *shield* de engajamento:

**Quadro 16 – Resumo das iniciativas de engajamento dos analistas de PLD**

<b>Hipótese</b>	<b>Planos de ação</b>
Hipótese 1: Falta integração com o mercado de PLD	<ul style="list-style-type: none"> <li>• Estimular analistas a obterem a certificação CPLD-FT</li> <li>• Contratar um <i>squad lead</i> com experiência em PLD</li> </ul>
Hipótese 2: Falta um processo de reconhecimento	<ul style="list-style-type: none"> <li>• Reservar espaço na reunião semanal para apresentação de iniciativas</li> <li>• Realizar o Round de Reconhecimento</li> <li>• Elaborar plano de remuneração variável</li> </ul>
Hipótese 3: Falta capacitação técnica em análise de dados	<ul style="list-style-type: none"> <li>• Criar um programa continuado de capacitação em análise de dados</li> </ul>

Fonte: elaborado pelo Autor

#### **4.4 Resumo do Plano**

O quadro a seguir resume todas as iniciativas que foram propostas para alcançar os dois objetivos detalhados, juntamente com o OKR que cada uma delas buscava cumprir.

**Quadro 17 - Resumo do plano de ação para o *squad* de PLD**

<b>Objetivo</b>	<b>Nome do projeto</b>	<b>Composição do time</b>	<b>Estimativa de entrega</b>
<b>Objetivo 1: Aumentar a precisão dos alertas de PLD</b>			
1.1 Criar avaliação de riscos e dimensionamento de quantidade de alertas	<i>Risk-based Approach</i>	1 coordenador de <i>Analytics</i> ; 1 Analista de negócios	Fevereiro/2019
1.2 Criar um novo modelo de detecção de suspeitos de lavagem de dinheiro	Criação do modelo de <i>Machine learning</i>	1 coordenador de <i>Analytics</i> ; 1 Analista de dados; 1 Analista de negócios	Fevereiro/2019
<b>Objetivo 2: Aumentar a produtividade dos analistas de PLD</b>			
2.1 Desenvolver nova plataforma de registro de investigações que integra diferentes sistemas	Sistema de <i>backoffice</i>	1 coordenador de PLD; 2 analistas juniores de PLD	Março/2019
2.3 Elaborar modelo de avaliação de qualidade interna das investigações	Modelo de <i>Quality Assessment</i>	1 analista sênior de PLD; 1 analista júnior de PLD	Março/2019
2.2 Criar plano de engajamento e aumento de motivação dos analistas	Plano de engajamento	1 coordenador de PLD; 1 analista júnior de PLD	Fevereiro/2019

Fonte: elaborado pelo Autor

No próximo capítulo, serão exibidos os resultados obtidos com cada uma das iniciativas, junto a uma análise crítica de cada um deles.



## 5 RESULTADOS E DISCUSSÃO

Devido ao processo adotado de análise e granularização de cada problema a ser atacado, foi possível criar projetos com duração de poucos meses, o que acabou permitindo ao Autor deste Trabalho de Formatura apresentar os resultados obtidos após a implementação de todos os planos descritos neste documento.

### 5.1 Análise dos resultados obtidos

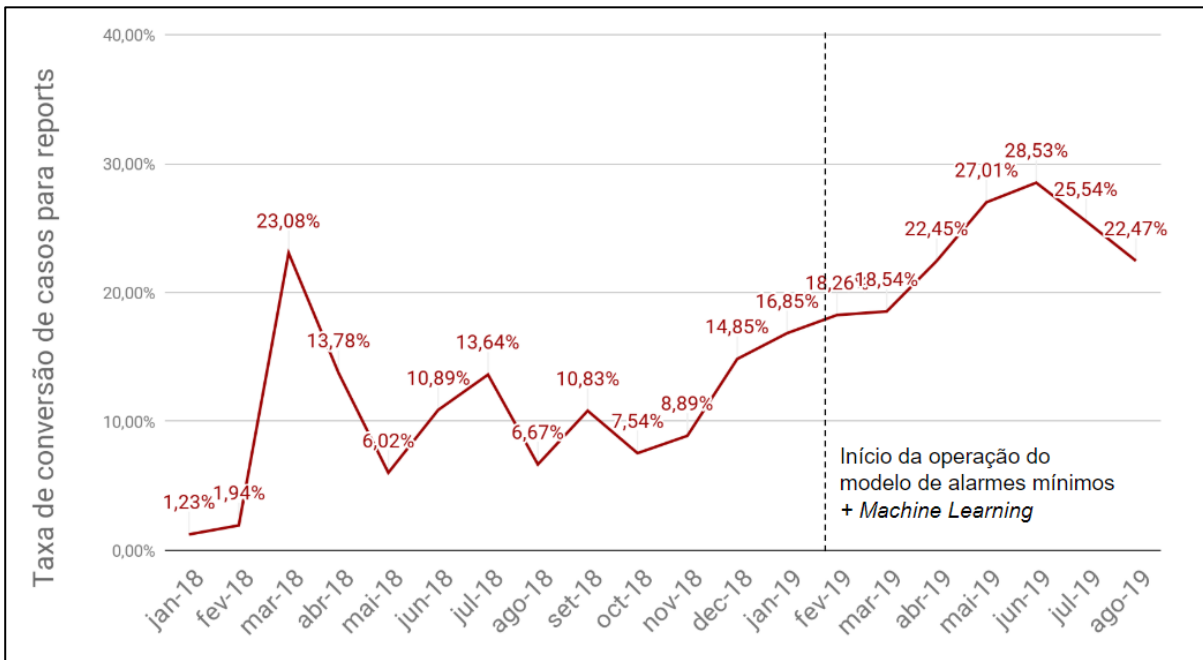
Ao fim do primeiro trimestre de 2019, foi possível entregar a tempo todos os projetos que o *squad* se propôs a fazer. Entretanto, nem todas as métricas definidas pelos OKRs no capítulo "3.8 Definição de OKRs (*Objective Key Results*)" puderam ter impacto visível naquele mesmo semestre, uma vez que o tempo de coleta de resultados para alguns dos objetivos foi curto. Desta forma, o Autor do Trabalho de Formatura incluiu na análise o acompanhamento das métricas também ao longo dos primeiros meses do segundo semestre de 2019, para que os impactos de cada mudança pudessem ter um horizonte de tempo de coleta mais longo.

A seguir, serão explicitados cada um dos OKRs, que serão acompanhados por gráficos mostrando a evolução da métrica definida ao longo do tempo.

**Objetivo:** Criar avaliação de riscos e dimensionamento da quantidade de alertas

**Métrica:** Taxa média de conversão de casos analisados para reportes (em %)

**Meta Q1/19:** 30%

**Gráfico 12 - Evolução da taxa de conversão de casos para reportes**

Fonte: elaborado pelo Autor

Nota-se pelo gráfico uma melhoria considerável na taxa de conversão de casos para reportes ao Coaf, embora o aumento não tenha sido suficiente para atingir a meta de Q1/2019. A implementação do novo dimensionamento de alertas seguindo o *Risk-Based Approach* ocorreu somente em Fevereiro, e pode ser observado um pico de desempenho no segundo trimestre de 2019, com a taxa de conversão atingindo o valor máximo de 28,53% em Junho. Considerando a média mensal da taxa antes da implementação e após a implementação, é possível verificar um aumento de cerca de 12 p.p.

O time ficou satisfeito com a melhora significativa do desempenho do novo framework de dimensionamento, e com o aumento consistente na taxa de conversão desde o início da implementação até o pico histórico foi surpreendente. Entretanto, pode-se notar uma queda na taxa de conversão nos meses de Julho e Agosto, que se deve principalmente à deterioração do modelo de *Machine learning* com o passar do tempo - um fenômeno que será melhor explicado no gráfico seguinte.


Para o futuro, a equipe decidiu realizar no segundo semestre de 2019 um novo estudo baseado em risco para recalibrar os valores-referência e os gatilhos de cada alerta mínimo, com o intuito de impedir a deterioração da taxa de conversão ao longo do tempo. Dependendo do grau das mudanças, a equipe considera instaurar um processo contínuo de monitoramento e aprimoramento desses parâmetros.

**Objetivo:** Criar um novo modelo de detecção de suspeitos de lavagem de dinheiro

**Métrica:** Taxa média de conversão de casos analisados para reportes provenientes do modelo de *Machine learning* (em %)

**Meta Q1/19:** 40%

**Gráfico 13 - Taxa de conversão *Machine learning* vs. Alarmes mínimos**



Fonte: elaborado pelo Autor

O objetivo em questão possui relação direta com o anterior, na medida em que o modelo de *Machine learning*, concebido justamente para aumentar a taxa de conversão para reportes, teria de responder por uma grande parcela na detecção de suspeitos de alto risco de lavagem de dinheiro. Esperava-se que a acurácia do modelo fosse ainda maior do que a taxa de conversão do novo framework inteiro, e, portanto, a meta de taxa de conversão foi estabelecida como sendo maior (40%).

Pode-se notar que a meta tampouco foi atingida. O modelo apresentou seu pico de acurácia em Maio, porém se deteriorou rapidamente depois disso. Este fenômeno, conhecido como *Concept Drift*, é causado pela mudança inesperada das propriedades estatísticas da variável-alvo que o modelo está tentando prever. Como o comportamento dos lavadores de dinheiro é dinâmico, e tende a mudar ao longo do tempo conforme os mecanismos de detecção do Sistema Financeiro Nacional vão se aprimorando, era esperado que a performance do

modelo se deteriorasse, e um novo retreino dele tivesse que ser realizado. Entretanto, o Autor e sua equipe não esperavam que a deterioração ocorresse de forma tão rápida.


Como próximos passos, a equipe decidiu esperar reunir mais observações de casos sendo avaliados pelo modelo atual, para que o retreino do modelo possa ser feito com uma amostra maior de dados, que deve levar a uma melhoria significativa na performance do modelo. Caso a taxa de conversão de casos caia para um nível inferior à média dos 6 meses anteriores à implementação do modelo, o retreino do modelo seria antecipado.

**Objetivo:** Desenvolver nova plataforma de registro de investigações que integra diferentes sistemas

**Métrica:** Número de investigações realizadas por dia por analista

**Meta Q1/19:** 4,0

**Gráfico 14 - Evolução no número de casos analisados por analista por dia**



Fonte: Elaborado pelo Autor

A implementação do sistema "Detetive", realizada em Março de 2019, provocou um aumento significativo de número médio de casos por analista por dia.

No mês de implementação, devido à alta carga de trabalho que foi exigida dos membros da equipe, e também por conta do período de adequação deles com a nova ferramenta, pôde-se observar uma leve queda no número médio de casos analisados. Entretanto, logo em seguida, o ganho de eficiência gerado com a centralização de registro de informações em uma única

plataforma foi tão significativo que a média de casos analisados saltou para 3,96 no segundo trimestre de 2019 - um ganho de quase 80% em relação à média do primeiro trimestre.


Diferentemente dos ganhos marginais obtidos com o modelo de *Machine learning*, que se reduzem com o passar do tempo, a nova plataforma já foi incorporada de forma definitiva pela equipe e espera-se que o ganho de eficiência seja permanente para o *squad* de PLD.

**Objetivo:** Elaborar modelo de avaliação de qualidade interna das investigações

**Métrica:** Nota média de avaliação de reportes ao Coaf (de 1 a 4)

**Meta Q1/19:** 3,5

**Gráfico 15 - Nota média mensal do reporte enviados ao Coaf**



Fonte: Elaborado pelo Autor

A implementação da operação de *Quality Assessment* também resultou em importantes ganhos para o *squad* nas notas médias dos reportes enviados ao Coaf. A equipe que trabalhou no desenvolvimento do projeto avalia que ainda mais importante que a metodologia introduzida de avaliação de reportes foi a instauração de uma cultura de controle de qualidade.

Ao alocar analistas para revisarem o trabalho de outros analistas, eles não somente aprendiam com os erros cometidos pelos Autores do reporte que estavam analisando, mas também se tornavam mais diligentes na hora de escreverem seus próprios reportes. Isto fez com que houvesse um ganho generalizado de qualidade desses documentos que eram enviados ao

Coaf, o que gerou o aumento de cerca de 25% na média das notas do segundo trimestre em comparação ao primeiro trimestre.


A equipe do projeto também avalia que as mudanças realizadas trouxeram ganhos que provavelmente serão duradouros, uma vez que os analistas ficaram motivados para que a cultura de qualidade fosse mantida e repassada para novos analistas que fossem contratados para o *squad*.

**Objetivo:** Criar plano de engajamento e aumento de motivação dos analistas

**Métrica:** Nota média de satisfação dos analistas em pesquisa de engajamento (de 0 a 10)

**Meta Q1/19:** 9

**Gráfico 16 - Nota de engajamento dos analistas de PLD**



Fonte: Elaborado pelo Autor

A medição do engajamento dos analistas de PLD era inexistente antes da implementação do projeto, e, portanto, havia grande incerteza sobre a validade da meta que foi instaurada. Entretanto, para a surpresa dos analistas do *squad*, foi possível atingir no segundo trimestre o exato valor que fora definido para a meta do primeiro trimestre.

As ações de engajamento geraram um grande ganho de motivação dos analistas nos primeiros meses, mas parecem ter começado a perder efeito nos meses posteriores, o que leva a crer que é necessário um esforço contínuo para que o trabalho dos analistas seja reconhecido

de formas diferentes, e que os mecanismos de enriquecimento de trabalho estejam sempre sendo repensados.

O grande ganho de engajamento em Agosto de 2019 provavelmente se deve ao fato de que um novo grupo de analistas de PLD se juntou ao *squad*, o que gerou oportunidades de ensinamento por parte dos analistas mais experientes e gerou um ganho geral de satisfação no clima da equipe.

## 5.2 Impactos organizacionais

Os projetos realizados no *squad* de PLD receberam grande destaque dentro da *Fintech X*. Não só os resultados foram satisfatórios, mas também o uso de tecnologia e dados para resolver problemas em um campo de conhecimento que carece de inovações no ecossistema de serviços financeiros brasileiro foi bastante louvado pela Diretoria da empresa.

Por conta do trabalho realizado, o Autor do Trabalho de Formatura e o Coordenador de *analytics* puderam apresentar tudo o que foi feito em duas ocasiões de impacto e visibilidade dentro da empresa: no Fórum de Decisões, que é realizado quinzenalmente e reúne todos os analistas de negócios e cientistas de dados, para que possam compartilhar as análises e projetos de maior impacto organizacional, e no “Coffee-break” da empresa, o evento de maior relevância na *Fintech X*, que é realizado mensalmente e no qual são convidados todos os funcionários, incluindo a Diretoria.

No Coffee-Break, um evento que dura aproximadamente uma hora, sempre há um recado da liderança da empresa a todos os funcionários, e também a apresentação de um time convidado pela Diretoria, para contar sobre algum projeto que tenha tido grande relevância organizacional. O fato de o Autor do Trabalho de Formatura e seu líder terem sido convidados a falar sobre seu projeto neste evento foi um grande testemunho à qualidade do que foi entregue e do impacto que os projetos tiveram no *squad* de PLD.

Além disso, por fim, o Coordenador de *analytics* de PLD recebeu um prêmio interno denominado “Just Do It” que é atribuído semestralmente à pessoa que mais realizou contribuições “sem desculpas” para a empresa, ou seja, que crescem frente às adversidades e superam grandes obstáculos para entregar o que é proposto. Esse prêmio foi criado em 2018, e o coordenador foi a terceira pessoa na *Fintech X* a recebê-lo - mais um indicativo da percepção positiva que a empresa teve com a transformação realizada no *squad* de PLD.

### 5.3 Benefícios conjunturais ao Sistema Financeiro Nacional

O Brasil passa por um momento de transformação na Prevenção à Lavagem de Dinheiro e Financiamento ao Terrorismo. O Coaf, com o desejo de automatizar cada vez mais seus processos internos e aprimorar seus sistemas de processamento de dados, tem trabalhado no aperfeiçoamento do sistema de gerenciamento de risco e sistema de tecnologia da informação – denominado SISCOAF. Segundo o órgão, este aprimoramento tornará possível uma maior qualidade e tempestividade na entrega às Autoridades responsáveis das investigações dos delitos descritos na Lei nº 9.613/98.

Como foi amplamente noticiado, centenas de Relatórios de Inteligência Financeira (RIF) produzidos em 2018 municiaram grandes operações de combate à corrupção e à lavagem de dinheiro, como a “Lava Jato”, a “Cui Bono”, a “Greenfield”, entre outras, assim como diversas investigações contra grandes organizações criminosas. O impacto dessas investigações tem aumentado o conhecimento da importância deste assunto por brasileiros de todas as regiões do país.

Neste contexto, as *fintechs* possuem potencial de alavancar todo o seu conhecimento e expertise em ferramentas tecnológicas para identificar casos suspeitos com maior grau de precisão, além de otimizar processos de sua operação de forma ainda mais ágil que as instituições financeiras mais tradicionais. O trabalho realizado pelo Autor e sua equipe reflete o desejo de que a PLD seja vista como um assunto de cada vez mais importância no Brasil, e explicita os ganhos operacionais que podem ser atingidos caso outras instituições também queiram alavancar seus resultados ao empregar dados e sistemas nesta jornada.



## 6 CONCLUSÕES

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 em 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.

Neste contexto, a série de mudanças promovida pelo Autor do Trabalho de Formatura e sua equipe no campo de Prevenção à Lavagem de Dinheiro mostra que é possível operar segundo o método ágil mesmo em áreas consideradas de “defesa” de um banco, e que alavancar o uso de dados de forma intensiva e descentralizada pode trazer ganhos de eficiência operacional consideráveis.

Inicialmente, neste Trabalho, partiu-se de dados existentes para realizar uma análise da operação de PLD vigente, detalhando as principais métricas de produtividade, a forma de interação entre os times e o processo de investigação dos casos suspeitos de lavagem de dinheiro. Nesta etapa, foi utilizada a experiência do próprio autor em ter trabalhado durante meses junto aos analistas de PLD.

Em seguida, foram elencados os principais problemas relacionados às métricas de produtividade, e as possíveis causas-raízes dos problemas encontrados foram determinadas. Para cada uma delas foi elaborada uma proposta de plano de ação específica. Por fim, cada uma foi inserida em uma posição específica na Matriz de Impacto X Esforço, e as que trariam maior retorno absoluto ao time foram escolhidas para serem priorizadas.

Após o procedimento de identificação e resolução de problemas descrito, partiu-se para a execução de cada um dos projetos. Para atingir o objetivo de melhorar a precisão dos alertas de PLD, foi elaborada uma avaliação baseada em risco, juntamente com a criação de um modelo de detecção dividido entre os chamados “alarmes mínimos” e um algoritmo de *machine learning*, que operariam de forma paralela. Já para o segundo objetivo, com o intuito de aumentar a produtividade dos analistas, foi priorizado um projeto de criação de um sistema de *backoffice*, a implementação de uma avaliação de qualidade interna dos reportes gerados, e um plano de aumento de engajamento dos analistas de PLD.

Como é possível verificar pelos resultados descritos no capítulo anterior, ganhos rápidos em diversas métricas puderam ser obtidos após a implementação das medidas. Entretanto, nem

todas terão efeito permanente, e é necessário realizar um acompanhamento constante para verificar que elas não estão caindo para níveis abaixo do tolerado. Caso isto aconteça, será necessário realizar novos projetos para remediar a situação, como por exemplo, o provável retreino do modelo de *machine learning* que terá de ser feito no futuro.

Esta mentalidade de aprimoramento contínuo e iterativo, entretanto, não é nova para a *Fintech X* e para a maioria das *startups*. A aplicação da gestão ágil em uma área considerada mais rígida e burocrática – como costuma ser o caso das áreas de PLD e Compliance – é uma extensão natural da filosofia de trabalho que permeia a operação de todos os times dentro da *Fintech X*.

Por fim, além de todo o conhecimento em tópicos diversos em Engenharia de Produção adquirido pelo Autor durante a realização deste trabalho - desde conceitos já bastante tradicionais na literatura como Gerenciamento por Processos até temas mais modernos e recentes, como Governança de Dados e Gestão Ágil - espera-se que as contribuições relatadas influenciem positivamente no processo de modernização das operações de PLD em instituições financeiras pelo Brasil, e que o ganho de eficiência no combate ao crime organizado receba cada vez mais destaque pelos líderes dessas organizações, além de um maior reconhecimento por parte da sociedade brasileira.

## 7 REFERÊNCIAS BIBLIOGRÁFICAS

ABDALA, E. C. **A gestão orientada por processos: um estudo de caso em uma organização hospitalar brasileira.** 2º Congresso Brasileiro de Sistemas. Ribeirão Preto: [s.n.]. 2006.

ABPMP - ASSOCIATION OF BUSINESS PROCESS PROFESSIONALS (Brasil). **BPM CBOOK: Guia para o gerenciamento de processos de negócio corpo comum de conhecimento.** São Paulo, 2013. 453 p

ABRAHAMSSON, P. et al. **Agile Software development methods: Review and analysis.** VVT publications 478, Espoo/FL, 2002. Disponível em: <<https://www.vtt.fi/inf/pdf/publications/2002/P478.pdf>>. Acesso em: 25 jul. 2018.

AGRESTI, A. **Categorical data analysis.** 3. ed. Hoboken, New Jersey: Wiley-Interscience, 2013.

AGILE ALLIANCE. **Manifesto para Desenvolvimento Ágil de Software.** 2001. Disponível em: <<http://agilemanifesto.org/iso/ptbr/manifesto.html>>. Acesso em: 25 jul. 2019.

ANDERSON, B., FAGERHAUG, T., & BELTZ, M. (n.d.). **Root Cause Analysis and Improvement in the Healthcare Sector: A Step-by-Step Guide.** Milwaukee, WI: ASQ Quality Press, 2010. p146-147.

BANCO CENTRAL DO BRASIL. **Prevenção à lavagem de dinheiro e ao financiamento do terrorismo.** Disponível em <<https://www.bcb.gov.br/estabilidadefinanceira/lavagemdinheiro>>. Acesso em: 22 jul. 2019.

BONDI, André B. **Characteristics of scalability and their impact on performance.** Proceedings of the second international workshop on Software and performance – WOSP '00, 2002. 195 p.

COCKBURN, A. **Agile software development.** Boston: Addison-Wesley, 2002

CONSELHO DE CONTROLE DE ATIVIDADES FINANCEIRAS. **Relatório de Atividades 2018**. Relatório. Brasília, 2018.

DAMIAN, I. P. M.; BORGES, L. S.; PÁDUA, S. I. D. D. **A importância das tarefas e os fatores críticos de sucesso para o gerenciamento de processos de negócios**. Revista de Administração da UNIMEP, 13, n. 2, Maio/Agosto 2015. 162- 185. Disponível em: 112 <<http://www.raunimep.com.br/ojs/index.php/regen/editor/submissionEditing/899#scheduling> >. Acesso em: 11 de Agosto 2019.

DALE, B.G; VAN DER WIELE, T; VAN IWAARDEN, J. **Managing Quality**. 5th ed. Victoria/AU: Blackwell Publishing, 2007

DOERR, J. **Measure What Matters: How Google, Bono, and the Gates Foundation Rock the World with OKRs**. Penguin Publishing Group, 2008. 31 p.

DRUCKER, P.R. **Management: Taks, Responsibilities and Practices**. New York: Harper & Row, 1973.

ÉPOCA NEGÓCIOS. Investimento em *startups* brasileiras cresce 51% em 1 ano -**Época Negócios**. Disponível em: <<https://epocanegocios.globo.com/Empresa/noticia/2019/05/epoca-negocios-investimento-em-startups-brasileiras-cresce-51-em-1-ano.html>>. Acesso em: 10 de Agosto de 2019.

FATF, **International Standards on Combating Money Laundering and the Financing of Terrorism & Proliferation**, FATF, Paris, France, 2012.

FITZGERALD B, STOL, KJ, O’SULLIVAN R and O’BRIEN D. **Scaling Agile Methods to Regulated Environments: An Industry Case Study, Proceedings of 35th International Conference on Software Engineering (ICSE)**, IEEE Publications, San Francisco, USA, 2013. p. 863-872.

FREEMAN, R. Edward. **STRATEGIC MANAGEMENT: A STAKEHOLDER APPROACH**. Cambridge University Press, 2010. Disponível em: <

[https://books.google.com.br/books?id=NpmA\\_qEiOpkC&pg=PA1&hl=ptPT&source=gb\\_s\\_to\\_c\\_r&cad=4#v=onepage&q&f=false](https://books.google.com.br/books?id=NpmA_qEiOpkC&pg=PA1&hl=ptPT&source=gb_s_to_c_r&cad=4#v=onepage&q&f=false) >. Acesso em: 30 de Julho de 2019

GILAD, Itamar. **Why Prioritization by Impact/Effort Doesn't Work**. 2017. Disponível em: <<https://www.linkedin.com/pulse/why-prioritization-impacteffort-doesnt-work-itamar-gilad/>>. Acesso em: 30 de Julho 2019.

GONÇALVES, F. M. **Breve histórico da evolução do combate à lavagem de dinheiro**. Consultor Jurídico, Janeiro 2014. Disponível em: <<https://www.conjur.com.br/2014-jan-12/segunda-leitura-evolucao-combate-lavagem-dinheiro-mundo>>. Acesso em 19 de Junho 2019.

GONÇALVES, J. E. L. **As Empresas São Grandes Coleções De Processos**. Revista de Administração de Empresas, São Paulo, 40, n. 1, 2000. 6-19. Disponível em: <<http://www.scielo.br/pdf/rae/v40n1/v40n1a02.pdf>>. Acesso em: 11 Agosto 2019.

GRAHAM, P. **“Startup = Growth”**. Disponível em: <<http://www.paulgraham.com/growth.html>>. Acesso em: 26 de Maio de 2019.

HANLEY, J. A.; MCNEIL, B. J., **The meaning and use of the area under a receiver operating characteristic (ROC) curve**, Radiology, vol. 143, 1982. p. 29–36.

HAYES, R., PISANO, G., UPTON, D. e WHEELWRIGHT, S.; **Operations, Strategy and Technology: Pursuing the Competitive Edge**. New York: John Wiley, 2005.

HIGHSMITH, J.; COCKBURN, A.. **Agile Software Development: The Business of Innovation**. *Computer*, v. 34, n.9, 2001. p.120–127.

HOSMER, D. W.; LEMESHOW, S. **Applied Logistic Regression**. [S.l.]: Wiley, 2000.

JAMES, G. et al. **An Introduction to Statistical Learning**. New York: Springer New York, 2014.

KHATRI, V.; BROWN, C. V. **Designing Data Governance**. *Communications of the ACM*, v. 53, n. 1, 2010.

KIMBALL, R. **The *data warehouse* toolkit: the complete guide to dimensional modeling**. Nova York: Wiley, 2002. 436 p.

KOLTAY, T. **Data governance, data literacy and the management of data quality**. *International Federation of Library Associations and Institutions*, v. 42, n. 4, 2016. p. 303-312.

KUHN, M; JONHSON, K. **Applied Predictive Modeling**. New York: Springer, 2013.

KUME, Hitoshi. **Métodos estatísticos para melhoria da qualidade**. [Belo Horizonte]: Instituto AOTS do Brasil/ Editora Gente, 1993.

LIU, C.; LI, Q.; ZHAO, X. **Challenges and opportunities in collaborative business process management: Overview of recent advances and introduction to the special issue**. *Information Systems Frontiers*, 11, Julho 2009. 201-209. Disponível em: <[https://www.researchgate.net/publication/220198739\\_Challenges\\_and\\_opportunities\\_in\\_collaborative\\_business\\_process\\_management\\_Overview\\_of\\_recent\\_advances\\_and\\_introduction\\_to\\_the\\_special\\_issue](https://www.researchgate.net/publication/220198739_Challenges_and_opportunities_in_collaborative_business_process_management_Overview_of_recent_advances_and_introduction_to_the_special_issue)>. Acesso em: 11 de Agosto 2019.

MACHADO, F. N. R. **Tecnologia e projeto de *data warehouse* : uma visão multidimensional**. São Paulo: Érica, 2006. 318 p.

McAFEE, A.; BRYNJOLFSSON, E. **Big Data: The Management Revolution**. *Harvard Business Review*, v. 90, n. 10, 2012. p. 60.

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

NEVES, M. A. **Prevenção e Combate à Lavagem de Dinheiro em Instituições Financeiras – a Importância da Atuação da Auditoria Interna**. Rio de Janeiro, 2003.

PROFESSIONALS, A. O. B. P. M. **BPM CBOOK Versão 3.0**. 1st. ed. [S.l.]: ABPMP Brasil 2013, 2013.

RAMOS, S. E. B. **A lavagem de dinheiro por meio de paraísos fiscais como crime transnacional: A cooperação internacional na recuperação de ativos**. *Âmbito Jurídico*, Rio Grande, XIX, n. 147, Abril 2016. Disponível em: <[http://ambitojuridico.com.br/site/?n\\_link=revista\\_artigos\\_leitura&artigo\\_id=17074](http://ambitojuridico.com.br/site/?n_link=revista_artigos_leitura&artigo_id=17074)>. Acesso em: 22 de Junho de 2019.

RIES, E. **The Lean Startup: How Today's Entrepreneurs Use Continuous Innovation to Create Radically Successful Businesses**. 1. ed. New York: Crown Business, 2011. 336 p.

SCHWABER, K; BEEDLE, M. **Agile Software Development with Scrum**. Prentice-Hall, 2002.

SLACK, Nigel. **Administração da produção**. São Paulo: Atlas, 1997.

SMART, D. P. A.; MADDERN, H.; MAULL, D. R. S. **Understanding Business Process Management: Implications For Theory And Practice**. Exeter: [s.n.]. 2009.

SUTHERLAND, Jeff. **Agile Can Scale: Inventing and Reinventing SCRUM in Five Companies**. *CUTTER IT journal*, v.14, n.12, p. 5-11, dez. 2001. Disponível em: <<https://web.archive.org/web/20131217174707/http://www.controlchaos.com/storage/scrumrticles/Sutherland%20200111%20proof.pdf>>. Acesso em: 25 de Julho de 2019.

UOL ECONOMIA. **5 maiores bancos concentram mais de 80% dos depósitos e empréstimos, diz BC** - Uol Economia. Disponível em: <<https://economia.uol.com.br/noticias/redacao/2019/05/28/bancos-concentracao-emprestimos.htm>>. Acesso em: 10 de Agosto de 2019.

WEBER, K.; OTTO, B.; ÖSTERLE, H. **One Size Does Not Fit All—A Contingency Approach to Data Governance**. *ACM Journal of Data and Information Quality*, v. 1, n. 1, 2009.

WITTEN, I. H.; FRANK, E. **Data Mining: Practical *Machine learning* Tools and Techniques with Java Implementations**. San Francisco, CA: Morgan Kaufmann, 2005.

WOJTCZAK, A.. **Glossary of Medical Education Terms. Institute for International Medical Education**, White Plains, New York, USA, 2002.