



DISSERTAÇÃO DE MESTRADO PROFISSIONAL

**Proposta de *framework* de *compliance* para proteção de dados de risco de crédito em atendimento à Lei Geral de Proteção de Dados Pessoais (LGPD) e o Open Finance**

**Regilson Vasconcellos Jesus**

Programa de Pós-Graduação Profissional em Engenharia Elétrica

DEPARTAMENTO DE ENGENHARIA ELÉTRICA

FACULDADE DE TECNOLOGIA

UNIVERSIDADE DE BRASÍLIA

UNIVERSIDADE DE BRASÍLIA  
Faculdade de Tecnologia  
Departamento de Engenharia Elétrica

DISSERTAÇÃO DE MESTRADO PROFISSIONAL

**Proposta de *framework* de *compliance* para proteção de dados de risco de crédito em atendimento à lei geral de proteção de dados pessoais (LGPD) e o open finance**

**Regilson Vasconcellos Jesus**

*Dissertação de Mestrado Profissional submetida ao Departamento de Engenharia Elétrica como requisito parcial para obtenção do grau de Mestre em Engenharia Elétrica*

Banca Examinadora

Prof. Daniel Alves da Silva, Dr., UnB \_\_\_\_\_

*Orientador*

Prof. Georges Daniel Amvame Nze, Dr., UnB \_\_\_\_\_

*Examinador Interno*

Prof. Gilmar dos Santos Marques, Dr., FAP/DF \_\_\_\_\_

*Examinador Externo*

Prof. Fábio Lúcio Lopes de Mendonça, Dr., UnB \_\_\_\_\_

*Suplente*

## FICHA CATALOGRÁFICA

VASCONCELLOS JESUS, REGILSON

Proposta de *framework* de *compliance* para proteção de dados de risco de crédito em atendimento à lei geral de proteção de dados pessoais (LGPD) e o open finance, [Distrito Federal] 2024. Xvi 101 p., 210 x 297 mm (ENE/FT/UnB, Mestre, Engenharia Elétrica, 2024).  
Dissertação de Mestrado Profissional - Universidade de Brasília, Faculdade de Tecnologia.  
Departamento de Engenharia Elétrica.

1. Open Finance

2. LGPD

3. Score de crédito

4. Risco de crédito

5. Compliance

I. ENE/FT/UnB

II. Título (série)

PUBLICAÇÃO: PPEE.MP.070

## REFERÊNCIA BIBLIOGRÁFICA

JESUS, R. (2024). PROPOSTA DE *FRAMEWORK* DE *COMPLIANCE* PARA PROTEÇÃO DE DADOS DE RISCO DE CRÉDITO EM ATENDIMENTO À LEI GERAL DE PROTEÇÃO DE DADOS PESSOAIS (LGPD) E O OPEN FINANCE. Dissertação de Mestrado Profissional, Departamento de Engenharia Elétrica, Universidade de Brasília, Brasília, DF, 101 p.

## CESSÃO DE DIREITOS

AUTOR: Regilson Vasconcellos Jesus

TÍTULO: Proposta de *framework* de *compliance* para proteção de dados de risco de crédito em atendimento à lei geral de proteção de dados pessoais (LGPD) e o open finance.

GRAU: Mestre em Engenharia Elétrica ANO: 2024

É concedida à Universidade de Brasília permissão para reproduzir cópias desta Dissertação de Mestrado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. Do mesmo modo, a Universidade de Brasília tem permissão para divulgar este documento em biblioteca virtual, em formato que permita o acesso via redes de comunicação e a reprodução de cópias, desde que protegida a integridade do conteúdo dessas cópias e proibido o acesso a partes isoladas desse conteúdo. O autor reserva outros direitos de publicação e nenhuma parte deste documento pode ser reproduzida sem a autorização por escrito do autor.

---

Regilson Vasconcellos Jesus

Depto. de Engenharia Elétrica (ENE) - FT

Universidade de Brasília (UnB)

Campus Darcy Ribeiro CEP 70919-970 - Brasília - DF - Brasil

## AGRADECIMENTOS

Qualquer grande desafio requer dedicação e resiliência para o alcance de resultados. Por isso gostaria de agradecer a todos que fizeram parte dessa vitória.

Primeiramente, gostaria de agradecer a Deus, pois sem sua graça derramada dia após dia em minha vida, não seria possível ter chegado até aqui.

Agradeço ao meu prof. orientador Dr. Daniel Alves da Silva por toda inspiração, paciência e ensinamentos no desenvolvimento deste trabalho no PPGEE Programa de Pós-graduação em Engenharia Elétrica.

Agradeço também aos membros da banca pela oportunidade, aos servidores administrativos do programa por todo auxílio prestado.

À minha esposa Marília por incentivar meu esforço, permanência e foco durante todos os momentos de dedicação a este trabalho.

Aos meus filhos, Lucas e Ana Regina, por toda compreensão nas horas ausentes do convívio familiar.

À minha mãe e ao meu pai (*in memoriam*) que investiram e empreenderam esforços desde sempre na minha formação profissional e pessoal.

Aos meus irmãos Adilson e Thiago, meus melhores amigos.

Meu muito obrigado de coração.

## RESUMO

O crescimento expressivo das instituições financeiras tanto no mercado nacional quanto global aumentou significativamente a competitividade pela manutenção e ampliação das carteiras de clientes, bem como popularizou o acesso ao crédito. Entretanto, a modelagem de score de crédito, tradicionalmente realizada com base em dados internos e regras proprietárias, enfrenta desafios de transparência e compliance. Visando alcançar vantagens competitivas e assegurar maior transparência na modelagem dos scores de crédito, este estudo propõe um *framework* fundamentado nos princípios do Open Finance e LGPD. Este *framework* tem como objetivo aumentar a precisão na avaliação de crédito e reduzir riscos e fraudes. Para enfrentar a falta de regulamentação específica, foi desenvolvida uma tabela inicial que identifica questões relevantes a serem consideradas na modelagem de scores de crédito, com base na resolução do Open Finance. Esta tabela foi posteriormente comparada e cruzada com as normas regulatórias nacionais vigentes, resultando na criação de um *framework* de auditoria robusto. A validação do *framework* envolveu uma análise detalhada e a adaptação dos modelos PLTR, Z-Score, e dos modelos de conjuntos homogêneos e heterogêneos. Cada um desses modelos foi revisitado para identificar suas fragilidades e propor melhorias, garantindo assim a eficácia do *framework* proposto. Este *framework* de compliance e proteção de dados para risco de crédito visa fornecer uma ferramenta abrangente e prática para as instituições financeiras, promovendo a conformidade com a LGPD e os princípios do Open Finance, além de aprimorar a segurança e a privacidade dos dados dos clientes. A adoção deste *framework* pode levar a uma maior confiança dos consumidores no sistema financeiro, redução de fraudes e uma avaliação de crédito mais justa e precisa.

Palavras-chave: Open Finance; LGPD; Score de crédito; Risco de crédito; Compliance.

## **ABSTRACT**

The significant growth of financial institutions in both the national and global markets has significantly increased competitiveness in maintaining and expanding customer portfolios, as well as popularizing access to credit. However, credit scoring modeling, traditionally based on internal data and proprietary rules, faces transparency and compliance challenges. Aiming to achieve competitive advantages and ensure greater transparency in the modeling of credit scores, this study proposes a framework based on the principles of Open Finance and the General Data Protection Regulation. This framework aims to increase accuracy in credit assessment and reduce risks and fraud. To overcome the lack of specific regulation, an initial table was developed that identifies relevant issues to be considered when modeling credit scores, based on the Open Finance resolution. This table was subsequently compared and cross-referenced with current national regulatory standards, resulting in the creation of a robust audit framework. Validation of the framework involved a detailed analysis and adaptation of the PLTR (Penalized Logistic Tree Regression), Z-Score, and homogeneous and heterogeneous set models. Each of these models was revisited to identify their weaknesses and propose improvements, thus ensuring the effectiveness of the proposed framework. This credit risk compliance and data protection framework aims to provide a comprehensive and practical tool for financial institutions, promoting compliance with LGPD and Open Finance principles, as well as improving the security and privacy of customer data. The adoption of this framework can lead to greater consumer confidence in the financial system, reduced fraud and a fairer and more accurate credit assessment.

**Keywords:** Open Finance; GDPR; Credit score; Credit risk; Compliance.

## LISTA DE FIGURAS

Figura 1 — Liberação de crédito em 2024.....	20
Figura 2 — Ilustração da Arquitetura Open Finance.....	41
Figura 3 — Elementos-chave de implantação da LGPD.....	44
Figura 4 — Elementos-chave de implantação da RGD.....	47
Figura 5 — Número total de multas aplicadas ao longo de 2018 até 2024.....	52
Figura 6 — Fluxo de elaboração do framework.....	56

## LISTA DE QUADROS

Quadro 1 — Revisão da literatura .....	23
Quadro 2 — Critérios relevantes baseados no Open Finance .....	57
Quadro 3 — Análise dos itens da LGPD vs. critérios baseados no Open Finance ...	62
Quadro 4 — <i>Framework</i> proposto .....	68
Quadro 5 — Validação do modelo PLTR de acordo com o <i>framework</i> .....	71
Quadro 6 — Validação do modelo Z-Score de acordo com o <i>framework</i> .....	75
Quadro 7 — Validação do conjunto homogêneo de acordo com o <i>framework</i> .....	79
Quadro 8 — Validação do conjunto heterogêneo de acordo com o <i>framework</i>	83



## LISTA DE SIGLAS

ADPPA	<i>American Data Privacy Protection Act</i>
API	<i>Application programming interfaces</i>
AT	Ativo total
Bacen	Banco Central do Brasil
CDC	Código de Defesa do Consumidor
CNPJ	Cadastro Nacional de Pessoa Jurídica
CPF	Cadastro de Pessoa Física
EAD	<i>Exposure at default</i> (inglês) ou Exposição ao risco de inadimplência (português)
FIPP	<i>Fair Information Practice Principles</i> (inglês) ou Princípios de Práticas Justas de Informação (português)
KMV	Kealhofer Merton Vasicek
LGD	<i>Loss given default</i> (inglês) ou Perda em caso de inadimplência (português)
LGPD	Lei Geral de Proteção de Dados
N/A	Não se aplica
NC	Não compatível
PC	Parcialmente compatível
PD	<i>Probability of default</i> (inglês) ou Probabilidade de inadimplência (português)
PLTR	<i>Penalised Logistic Tree Regression</i> (inglês) ou Regressão de Árvore Logística Penalizada (português)
RGPD	Regulamento Geral sobre a Proteção de Dados
TC	Totalmente compatível
TI	Tecnologia da Informação
TIC	Tecnologia da Informação e Comunicações
TJUE	Tribunal de Justiça da União Europeia
UE	União Europeia
VaR	Valor em Risco
WC	<i>Working capital</i> (inglês) ou Capital de giro (português)

## SUMÁRIO

<b>1. INTRODUÇÃO</b> .....	<b>11</b>
<b>1.1. Motivação</b> .....	<b>13</b>
<b>1.2. Organização do trabalho</b> .....	<b>15</b>
<b>1.3. Objetivos do trabalho</b> .....	<b>15</b>
1.3.1. Objetivo geral.....	15
1.3.2. Objetivos específicos.....	16
<b>1.4. Trabalhos publicados</b> .....	<b>16</b>
<b>1.5. Metodologia de pesquisa</b> .....	<b>17</b>
<b>1.6. Contribuições do trabalho</b> .....	<b>18</b>
<b>2. ESTADO DA ARTE E REVISÃO BIBLIOGRÁFICA</b> .....	<b>20</b>
<b>2.1. Score de crédito</b> .....	<b>20</b>
<b>2.2. Modelo de score de crédito</b> .....	<b>26</b>
2.2.1. Modelo PLTR.....	27
2.2.2. Vantagens do modelo PLTR.....	28
2.2.3. Desvantagens do modelo PLTR.....	29
<b>2.3. Modelo Z-Score</b> .....	<b>30</b>
2.3.1. Vantagens do modelo Z-Score .....	32
2.3.2. Desvantagens do modelo Z-Score .....	33
<b>2.4. Riscos de crédito</b> .....	<b>34</b>
<b>2.5. Modelo de risco</b> .....	<b>35</b>
2.5.1. Modelo de conjunto homogêneo.....	35
2.5.2. Vantagens do modelo de conjunto homogêneo.....	36
2.5.3. Desvantagens do modelo de conjunto homogêneo.....	36
<b>2.6. Modelo de conjunto heterogêneo</b> .....	<b>37</b>
2.6.1. Vantagens do modelo de conjunto heterogêneo .....	38
2.6.2. Desvantagens do modelo de conjunto heterogêneo.....	39
<b>2.7. OPEN FINANCE</b> .....	<b>40</b>
<b>3. PANORAMA REGULATÓRIO: LEGISLAÇÕES NACIONAIS E INTERNACIONAIS</b> .....	<b>43</b>
<b>3.1. Panorama Brasil: Lei Geral de Proteção de Dados</b> .....	<b>43</b>
<b>3.2. Panorama europeu: Regulamento Geral sobre a Proteção de Dados</b> .....	<b>47</b>

<b>3.3. Estratégias do Regulamento Geral sobre a Proteção de Dados .....</b>	<b>48</b>
<b>3.4. Aplicação do Regulamento Geral sobre a Proteção de Dados.....</b>	<b>51</b>
3.4.1. Dados pessoais e processamento .....	51
3.4.2. Responsabilidades sob o Regulamento Geral sobre a Proteção de Dados ...	51
3.4.3. Extraterritorialidade do Regulamento Geral sobre a Proteção de Dados .....	52
3.4.4. Exceções à aplicação do Regulamento Geral sobre a Proteção de Dados....	53
<b>4. PROPOSTA DE <i>FRAMEWORK</i> DE RISCO DE CRÉDITO SEGURO .....</b>	<b>55</b>
<b>4.1. Etapa 1: organização da informação.....</b>	<b>56</b>
<b>4.2. Etapa 2: diagnóstico de aderência.....</b>	<b>61</b>
<b>4.3. Etapa 3: validação jurídica.....</b>	<b>67</b>
<b>5. RESULTADOS: VALIDAÇÃO E APLICAÇÃO DO <i>FRAMEWORK</i>.....</b>	<b>71</b>
<b>6. CONSIDERAÇÕES FINAIS .....</b>	<b>87</b>
<b>6.2. Proposta de trabalhos futuros.....</b>	<b>91</b>
<b>REFERÊNCIAS.....</b>	<b>92</b>

## 1. INTRODUÇÃO

Em escala global, foi Durand (1941) quem originou o estudo sobre *credit scoring*, o qual ficou conhecido como *Risk Elements in Consumer Installment Financing*. Trata-se de método estatístico de análise que separa bons e maus pagadores de empréstimos. A combinação probabilística de fatores associados à inadimplência determina o apetite creditício entre os pares, resultando em uma pontuação final, chamada de *scoring*.

Importante referenciar a pesquisa realizada em 2011 por especialistas do Banco Mundial, sob título de *General Principles for Credit Reporting*. De maneira geral, o documento conclui que: a) economias modernas devem ter como base os sistemas positivo e negativo de informação ao crédito do tomador ou financiamento; b) existem evidências empíricas de que o sistema de proteção ao crédito, o qual coleta e armazena informações positivas e negativas, permite uma avaliação de risco mais precisa; c) os sistemas de informação ao crédito promovem uma maior concorrência entre concedentes de crédito; d) os sistemas de informação, quando consolidados, podem fomentar os investimentos de empresas estrangeiras no mercado local (World Bank, 2011, p. 10-11).

Ainda, no continente europeu, a temática discorre em relação à proteção dos dados conforme a 5ª edição do *GDPR Enforcement Tracker Report (2024)*, importante relatório que lista ações sobre esforços para o cumprimento do Regulamento Geral sobre a Proteção de Dados (RGPD), norma que será abordada nas seções seguintes. Infere-se que a maioria das multas aplicadas são pertinentes à falta de conformidade, o qual assegura base jurídica para o tratamento de dados de seus clientes. Na maioria dos casos, as instituições controladoras não apresentam consentimento efetivo para o processamento de dados de seus clientes. Dessa forma, danos à imagem e prejuízos milionários por meio de pagamento de multas tendem a crescer.

No Brasil, a temática de cadastro de proteção ao crédito tem assumido protagonismo, sendo sua aplicabilidade de grande valia no contexto social consumerista nacional, tendo início na década de noventa, com a regulação do Código de Defesa do Consumidor (CDC), Lei n.º 8.078, de 11 de setembro de 1990. Logo, em 2011, com a Lei do Cadastro Positivo, Lei n.º 12.414, de 9 de junho de 2011,

ocorreu entendimento quanto à consulta de banco de dados de bons pagadores, autorizados pelo Banco Central do Brasil (Bacen), com ênfase na necessidade de transparência, proteção da honra e privacidade do consumidor. Além disso, por meio da Súmula n.º 550 de outubro de 2015, o Superior Tribunal de Justiça (STJ), reconheceu que a prática comercial é lícita, estando autorizada pela lei supracitada (Lei do Cadastro Positivo), respeitando os limites estabelecidos pelo CDC.

Não obstante, transpondo para 2018, com a implementação no país da Lei Geral de Proteção de Dados (LGPD), destacou-se a necessidade de abordagens inovadoras e seguras na avaliação de crédito, com atenção à proteção dos direitos fundamentais (Brasil, 2018). A partir desse período até os dias atuais, a atenção à segurança e *accountability*<sup>1</sup> segue avultando.

A discussão sobre o risco de crédito e a análise de crédito ganha ainda mais relevância no contexto brasileiro devido ao cenário econômico diversificado e dinâmico. O Brasil enfrenta desafios únicos, como a complexidade das transações financeiras e a diversidade socioeconômica da população, sendo considerado o segundo país com maior número de vítimas de fraudes financeiras no mundo (Santana, 2023). Vislumbrando diminuição destes números, as instituições financeiras brasileiras investem em média cerca de dois bilhões por ano em medidas de *cyber* segurança, conforme notícia da Federação Brasileira de Bancos (FEBRABAN, 2022).

As instituições financeiras rotineiramente categorizam seus clientes com base em regras internas e políticas corporativas, utilizando dados internos para essa finalidade. A própria Súmula n.º 550 do STJ versa que não há obrigatoriedade em revelar o cálculo e o método matemático utilizado. No entanto, a exatidão dessa categorização muitas vezes é desafiada pela dinâmica competitiva de mercado, podendo ocorrer divergências.

Dessa forma, a discussão sobre o *score* de crédito, com enriquecimento pela integração de dados alinhada às regulamentações locais, torna-se crucial para mitigar riscos, combater fraudes e garantir uma avaliação de solvência mais precisa dos clientes. Isso não apenas beneficia as instituições financeiras ao reduzir o risco de inadimplência, mas também promove a confiança dos consumidores em um sistema

---

<sup>1</sup> Uso de informações e adoção de condutas de forma transparente sob responsabilização das ações dos agentes (Denhardt; Denhardt, 2003).

financeiro mais robusto e seguro, evitando alta quantidade de judicialização (Zuliani, 2017).

Observando esse contexto, o trabalho objetiva a proposição de um *framework* de risco de crédito seguro, em consonância ao Open Finance e ao arcabouço normativo vigente, o qual avaliará a conformidade das práticas de classificação, especialmente no que se refere ao desenvolvimento de *scores*, com as diretrizes estabelecidas pela LGPD e na Resolução Conjunta nº 1, de 4 de maio de 2020, que dispõem sobre a implementação do Open Finance.

Durante a abordagem, discorreu-se sobre a capacidade de analisar o compartilhamento de dados sensíveis, garantindo a observância dos requisitos de segurança preconizados pela LGPD e pelo Open Finance. A ênfase recai sobre a necessidade de coletar, processar e relacionar informações relevantes de diversas fontes, bem como utilizar modelos avançados de coleta e análise de dados. A utilização dessa abordagem justifica pesquisas contínuas para aprofundar o entendimento do tema, assegurando segurança e confiabilidade e evitando violações que possam acarretar penalidades. Observa-se ainda os benefícios da capacidade de fornecer uma vasta quantidade de informações aliados à potência da disciplina computacional e aprendizado de máquina.

Essa estratégia complementa os dados já utilizados pelas instituições financeiras, contribuindo para reduzir riscos relacionados a fraudes e classificações inadequadas de clientes. Por fim, ao mitigar riscos e prevenir fraudes, essa abordagem não apenas resguarda as instituições financeiras, mas também protege pequenos empreendedores, contribuindo para a estabilidade econômica não somente em âmbito nacional, mas globalmente.

## **1.1. Motivação**

Em tempo, percebe-se um aumento do movimento de digitalização no setor financeiro, tendo cada vez mais *players* como *fintechs* e bancos cem por cento digitais somando-se ao mercado. Os clientes, por sua vez, acessam em grande escala serviços por meio de aplicativos em seus telefones móveis. Conseqüentemente, a indústria financeira sofrerá de um crescente escrutínio público quanto à segurança de seus dados por parte de órgãos controladores e reguladores (UE, 2024).

Diante dos crescentes desafios enfrentados pelas instituições financeiras em relação às fraudes e à segurança de dados, torna-se imperativo abordar o problema atual no contexto da análise de crédito e do *score* de crédito. Ao observar, as falhas de segurança em sistemas de rede, percebe-se que o vazamento de dados pessoais e sensíveis representa uma ameaça significativa para a integridade moral, social, econômica e jurídica dos usuários.

É amplamente reconhecido o aumento nos casos de vazamento e roubo de dados pessoais em grandes lojas e serviços on-line, evidenciando a necessidade urgente de implementar medidas eficazes. Em 2018, destacam-se incidentes notáveis, como o mau uso de dados de usuários pelo Facebook, a exposição da localização de usuários pelo Twitter e o vazamento de informações sensíveis de aproximadamente 500 milhões de hóspedes da Rede Marriot, incluindo brasileiros. Além disso, o setor de *e-commerce* no Brasil testemunhou o vazamento de informações pessoais e sensíveis de clientes da Netshoes, enquanto a Porto Seguro enfrentou a venda ilegal de dados pessoais, imagens de documentos e dados bancários (Pacete, 2021).

Nesse cenário, a implementação da LGPD, em 2020, representa um marco legal significativo, impactando organizações de todos os portes e setores, inclusive as do setor financeiro. A legislação propõe uma mudança para uma era pró-privacidade, na qual a aplicação de boas práticas e políticas de segurança torna-se indispensável. No contexto específico da análise de crédito e *score* de crédito, a LGPD destaca a importância da autonomia dos titulares de dados sobre suas informações, ao mesmo tempo em que impõe deveres significativos às instituições financeiras no que se refere à coleta, ao uso, à correção, à eliminação e à portabilidade de dados.

Para enfrentar esse desafio, a governança, gestão e transparência de dados emergem como pilares fundamentais. Em todo o ciclo de vida do produto ou serviço financeiro, é essencial considerar a privacidade, proteção, cuidado e segurança dos usuários e seus dados pessoais e sensíveis. A implementação de soluções de Tecnologia da Informação (TI) e segurança da informação, como análise e gerenciamento de dados, gerenciamento de consentimento, controle de acessos, eliminação de dados duplicados e mascaramento de dados, torna-se crucial para atender às exigências legais da LGPD e fortalecimento da segurança no setor financeiro.

## 1.2. Organização do trabalho

O trabalho foi desenvolvido em seis capítulos. O capítulo dois apresenta os diferentes modelos de *score* de crédito e de risco de crédito, sendo estes: PLTR, Z-Score, conjunto homogêneo e conjunto heterogêneo e seus aspectos técnicos, vantagens e desvantagens.

O capítulo três traz o panorama das leis e normas tanto no âmbito nacional quanto no internacional, além de um breve conceito sobre a tecnologia Open Finance. O capítulo quatro discorre sobre a proposta de *framework* otimizado de *score* de crédito, com suas respectivas etapas para o problema descrito no capítulo primeiro.

O capítulo cinco descreve as validações dos modelos conforme *framework* proposto e seus possíveis pontos de fragilidade. Por fim, o capítulo seis encerra o conteúdo com as conclusões e sugestões de trabalhos futuros.

## 1.3. Objetivos do trabalho

O objetivo geral deste estudo é desenvolver e propor um *framework* de risco de crédito seguro, que integre os princípios do Open Finance e o arcabouço normativo vigente, especialmente a LGPD. Este *framework* visa classificar e avaliar a confiabilidade dos usuários com base em seu histórico financeiro e comportamento de transação, permitindo que as instituições financeiras não apenas mitiguem os riscos associados a fraudes, mas também assegurem a conformidade com normas regulatórias rigorosas.

### 1.3.1. |Objetivo geral

Ao classificar e avaliar a confiabilidade dos usuários com base em seu histórico financeiro e comportamento de transação, as instituições podem não apenas mitigar riscos associados a fraudes, mas também garantir a conformidade com normas rigorosas, como a LGPD.



Dessa forma, o trabalho objetiva a proposição de um *framework* de Risco de Crédito Seguro em consonância ao Open Finance e ao arcabouço normativo preconizado.

### 1.3.2. Objetivos específicos

Em detalhamento ao objetivo geral, os objetivos específicos compreendem revisão, análise, proposição, avaliação e melhorias do modelo proposto, a saber:

- revisar amplamente a literatura existente sobre análise de crédito, modelos de *score* e as tecnologias associadas à segurança de transações financeiras sob o recorte de soluções disponíveis que fortalecem a avaliação de riscos;
- analisar a legislação vigente, com ênfase na LGPD e em leis complementares relacionadas à privacidade de dados no contexto da análise de crédito, identificando diretrizes específicas e exigências legais;
- propor um modelo tecnológico por meio de manual web acessível, que integre as diretrizes da LGPD e ofereça orientações claras sobre melhores práticas, conformidade e segurança no contexto da análise de crédito.
- avaliar possíveis vulnerabilidades nos modelos de *score* de crédito e nas práticas de análise de crédito, identificando pontos suscetíveis a fraudes e ameaças à segurança das informações; e
- apontar ajustes necessários aos modelos, durante a validação, garantindo sua eficácia e aplicabilidade prática no ambiente financeiro.

## 1.4. Trabalhos publicados

Durante a elaboração desta dissertação, foi publicado artigo científico propondo a descoberta de vantagens do uso da *Open Source Intelligence* (OSINT) pelas instituições financeiras e discorrendo sobre como mecanismos do atual Open Finance e *Data Mart* podem contribuir no auxílio para melhoria da classificação de pontuação dos clientes, visando mitigar riscos, fraudes e maior eficácia na tomada de decisão. A pesquisa resultou na seguinte publicação:

- JESUS, Regilson Vasconcellos; SILVA, Daniel Alves da; TORRES, José Alberto Souza *et al.* Open Source Intelligence: Classification and Mitigation of Risks and Fraud Within Financial Institutions. *In: 2023 18TH IBERIAN CONFERENCE ON INFORMATION SYSTEMS AND TECHNOLOGIES (CISTI), 2023 Aveiro, Portugal. Anais [...]. [S. l.]: IEEE, 2023. p. 1-5. DOI: 10.23919/CISTI58278.2023.10211291. Disponível em: <https://ieeexplore.ieee.org/document/10211291>.*

### 1.5. Metodologia de pesquisa

Observa-se que a metodologia clássica da pesquisa na engenharia indica que o método mais utilizado consiste em verificar na literatura a possibilidade de existirem soluções para a problemática estudada, ou soluções para problemas semelhantes (Berto; Nakano, 1999). Para a estrutura específica da blindagem na análise de score de crédito, normatizada por organismos internacionais e nacionais, além da solução Open Finance, ficou evidente a necessidade de conceber uma proposta de *framework* com foco na segurança dos dados utilizados conforme as normas legais computacionais.

Por isso, o trabalho de elaboração consistiu em descrever quais são os módulos propostos e o funcionamento deles através da proposição de um *framework* seguro de análise de score de crédito.

Ante o exposto, a metodologia utilizada, a elaboração desse *framework* é muito relevante, pois, além de ser o ponto central de orquestração das diversas barreiras de segurança, ele cria um cenário mais próximo da realidade, uma vez que incorpora todo o arcabouço legal e normativo acerca da referida análise.

No entanto, considerando a natureza científica do trabalho, faz-se necessária a verificação se tais ações e critérios utilizados no *framework*, podem de fato garantir a segurança, autenticidade e não conformidade dos dados pessoais dos usuários.

Dessa forma, a primeira etapa da abordagem metodológica visa atestar se a arquitetura proposta soluciona o referido problema. Para isso foi realizada pesquisa investigativa e teórica, em análises de discursos e do confronto com as ideias e publicações de especialistas na área de segurança da informação e na legislação LGPD que versa sobre a privacidade e o tratamento de dados pessoais.

Assim, pela natureza qualitativa, optou-se pelo uso de metodologia experimental, o qual a segunda etapa versa sobre a proposição de um protótipo experimental que considera cenários de validação de perguntas-chave que representem a realidade.

A terceira etapa, é feita com análise de resultados à luz do modelo experimental, buscando soluções de segurança frente às vulnerabilidades impostas pelo *framework*.

Sendo assim, fica organizada da seguinte maneira a metodologia do trabalho: estudo do problema e varredura na literatura (1); criação de uma proposta experimental (2); validação e teste experimental (3).

Estas etapas serão utilizadas para responder a seguinte questão de pesquisa: “Quais são as diretrizes identificadas na LGPD que não estão contempladas e impactam no modelo de *score* de crédito digital confiável?”.

## **1.6. Contribuições do trabalho**

O presente trabalho de pesquisa visa contribuir para:

- apresentar um modelo eficaz de análise de crédito, embasados nos preceitos e garantias da LGPD. O modelo proposto funcionaria como um guia abrangente para a implementação de análises a serem seguidas pelas instituições financeiras, especificamente voltado para fortalecer a segurança e a privacidade de dados no contexto da análise de crédito e na aplicação de modelos de *score*;
- propor diretrizes claras e acionáveis, oferecendo orientações específicas às instituições financeiras no âmbito da análise de crédito. Além disso, almeja-se que o guia seja adotado como uma referência prática pelas instituições financeiras, contribuindo para aprimorar a segurança, mitigar riscos de fraudes e fortalecer a conformidade com as regulamentações de privacidade de dados, particularmente a LGPD;
- promover treinamentos específicos para colaboradores envolvidos em processos que lidam com dados sensíveis, destacando a importância do cumprimento das normas de privacidade e segurança;

- integrar entre áreas de negócio, especialmente entre Tecnologia da Informação e Comunicações (TIC) e o departamento jurídico, assegurando uma colaboração coesa para a implementação eficaz da LGPD;
- implantar cultura de aprimoramento contínuo para avaliação da eficácia das medidas de segurança e conformidade ao longo do tempo. Favorecendo os processos conforme novas ameaças e mudanças normativas.

## 2. ESTADO DA ARTE E REVISÃO BIBLIOGRÁFICA

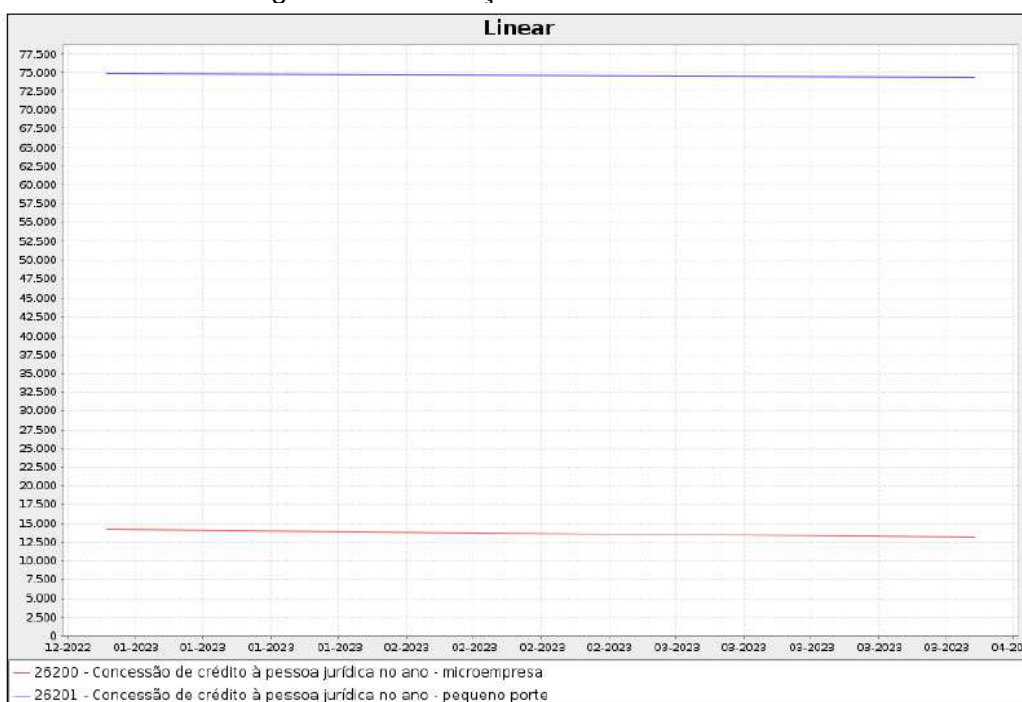
Este capítulo contém a revisão dos principais conceitos abordados nesta dissertação, corroborando com o entendimento da problematização supracitada, tais como: *score* de crédito, modelos de *score* de crédito, riscos financeiros, riscos de crédito, modelos de risco de crédito e Open Finance.

### 2.1. *Score* de crédito

Atualmente, os bancos comerciais têm em suas reservas bilhões de dólares disponíveis. Por isso, o setor de crédito transformou-se em uma indústria de grande relevância econômica. A grande quantidade desses empréstimos demonstra que pequenos refinamentos nas práticas de avaliação de crédito podem levar a consideráveis benefícios financeiros (Gunnarsson *et al.*, 2021).

O gráfico ilustrado pela Figura de 1 mostra a liberação de crédito somente para micro e pequenas empresas em milhões no ano de 2024 até o momento.

Figura 1 — Liberação de crédito em 2024



Fonte: Bacen, 2024.

O modelo de *score* de crédito é uma forma de avaliar o histórico financeiro de determinado consumidor (Arya; Echel; Wichman, 2013).

Caso um indivíduo deseje solicitar um empréstimo ou emissão de um cartão de crédito em uma instituição financeira, o *score* de crédito é uma das formas utilizadas pelas instituições para analisar o risco de concessão.

A pontuação de cada consumidor é feita com base em informações do banco de dados de birôs de crédito, pautada em seu comportamento de pagamentos vinculados ao seu Cadastro de Pessoa Física (CPF), como: empréstimos, utilização de cartões e as demais contas de consumo.

Assim, as instituições avaliam os riscos de concessão de crédito com base no histórico de transações, podendo avaliar se há risco ou não de concessão, frente ao montante solicitado. Observa-se que o número de consultas pelo CPF ou Cadastro Nacional de Pessoa Jurídica (CNPJ) também constam nas informações do *score* etc. (Arya; Echel; Wichman, 2013).

O autor ainda preconiza que as pontuações podem variar de zero a mil pontos, quanto maior for a pontuação menor será o risco de inadimplência, com isso, o consumidor terá benefícios, como a facilidade de adquirir empréstimos e demais operações financeiras.

Ainda, a pontuação de crédito é um valor que reflete a análise da solidez do histórico de crédito de determinado consumidor versus a probabilidade de cumprimento de obrigações financeiras. Essa pontuação é calculada a partir de uma análise estatística do histórico de crédito pessoal, sendo mantida por agências de crédito, como Experian, Equifax e TransUnion, que registram as transações de empréstimo e pagamento do consumidor (Arya; Echel; Wichman, 2013).

De acordo com a pesquisa dos autores conduzida em 2013, são considerados quatro elementos-chave que impactam em determinado comportamento de consumo: impaciência, impulsividade, disposição para assumir riscos e confiabilidade. É plausível supor que as pontuações de crédito mais baixas estejam correlacionadas com descontos mais significativos em pagamentos futuros.

Isso se deve ao fato de que a impaciência está relacionada à vontade de adiantar o consumo futuro para o presente por meio de empréstimos, tendo em vista que empréstimos mais substanciais aumentam o risco de inadimplência. Indivíduos impulsivos, por sua vez, tendem a ceder à tentação de contrair empréstimos para

gastos imediatos, tornando-se mais propensos a não cumprir com suas obrigações financeiras.

Além disso, a falta de confiabilidade pode igualmente contribuir para pontuações de crédito negativas, visto que os consumidores menos confiáveis costumam não honrar seus compromissos financeiros (Gunnarsson *et al.*, 2021).

No entanto, com o auxílio de modelos baseados em dados empíricos, as concedentes podem avaliar os consumidores que desejam o crédito de maneira mais eficaz e precisa. Isso resultou em aumento do interesse pela pontuação de crédito empiricamente fundamentada, resultando no desenvolvimento de várias técnicas comumente conhecidas como "modelos de pontuação de crédito" (Gunnarsson *et al.*, 2021).

O objetivo fundamental desses modelos é categorizar os solicitantes de crédito em dois grupos distintos: aqueles que são considerados bons candidatos a crédito, com maior probabilidade de reembolsar um empréstimo; e aqueles que são identificados como candidatos de alto risco, com maior probabilidade de não cumprir com suas obrigações financeiras (Gunnarsson *et al.*, 2021).

A extensa adoção de serviços financeiros tem redirecionado o interesse dos pesquisadores para a administração do risco de empréstimo, visando, por um lado, à diminuição dos perigos financeiros e, por outro lado, ao aumento dos ganhos associados. Sendo assim, o *score* de crédito é uma das formas de diminuição dos riscos financeiros, obtenção de informações sobre os consumidores, se, por exemplo, possuem muitas dívidas e se elas foram ou estão sendo pagas. Os riscos financeiros podem ser classificados como: riscos de crédito, riscos de mercado e riscos operacionais (Gunnarsson *et al.*, 2021).

No Quadro 1, compila-se a revisão da literatura abordando como os autores conceituam e exemplificam os riscos financeiros:

Quadro 1 — Revisão da literatura

TIPO	ENTENDIMENTO	EXEMPLOS	REFERÊNCIA
Risco de Crédito	Potencial de perda financeira que uma instituição financeira, pessoas jurídicas e pessoas físicas enfrentam quando não cumprem com os pagamentos de dívidas (Merton, 1974).	A inadimplência ocorre quando o mutuário não cumpre com as obrigações financeiras acordadas, o que pode levar a perdas financeiras significativas para o credor (BCB, 2020).	MERTON, Robert C. On the Pricing of Corporate Debt: The Risk Structure of Interest Rates. <b>The Journal of Finance</b> , v. 29, n. 2, p. 449–470, maio 1974; JARROW, Robert A; RUDD, Andrew. <b>Option Pricing</b> . [S. l.]: McGraw-Hill/Irwin, 1983.
Risco de contraparte	É um risco que pode afetar instituições financeiras, como bancos que dependem da confiabilidade de outras instituições para suas operações.	Um banco X faz um empréstimo de R\$ 10 milhões ao Banco Y, com vencimento em um ano, podendo ocorrer o risco do Banco Y não pagar o empréstimo em dia (inadimplência), então pode ocorrer a falência do Banco Y, e as possíveis causas podem ocorrer tais elas são: Deterioração da situação financeira do Banco Y, Eventos inesperados (desastres naturais, crises econômicas). As consequências para o Banco X podem ter perdas financeiras (incluindo juros) e danos à reputação (BCB, 2020).	DAMODARAN, A. <b>Gestão Estratégica do Risco</b> : uma referência para a tomada de riscos empresariais. Tradução: Felix Nonnenmacher. 1. ed. Porto Alegre: Bookman, 2009.



Quadro 1 — Revisão da literatura

(continuação)

TIPO	ENTENDIMENTO	EXEMPLOS	REFERÊNCIA
Risco de crédito de mercado	É um risco que está relacionado à volatilidade dos preços de títulos de dívida e outros instrumentos financeiros no mercado.	Esse risco pode ser agravado por preocupações com o crédito, o que pode levar a perdas financeiras significativas para os detentores desses títulos (IMF,2009).	JORION, P. <b>Financial Risk Manager Handbook</b> . 5. ed. Hoboken (EUA): Wiley, 2009. p. 752.
Risco de Mercado	É um conjunto de riscos financeiros que podem ser associados à volatilidade e às flutuações dos preços no mercado.	Os mais afetados podem ser os investidores, empresas, bancos que estão sendo relacionados em várias classes de ativos, por exemplo: ações, títulos, moedas e outros instrumentos financeiros que são negociados em bolsas e mercado (Hull; White, 2014).	HULL, John; WHITE, Alan. Valuing Derivatives: Funding Value Adjustments and Fair Value. <b>Financial Analysts Journal</b> , v. 70, n. 3, p. 46–56, maio 2014; HULL, John; WHITE, Alan. <b>Hull-White on Derivatives: A Compilation of Articles by John Hull and Alan White</b> . London: Risk Publications, 1996.

Quadro 1 — Revisão da literatura

(continuação)

TIPO	ENTENDIMENTO	EXEMPLOS	REFERÊNCIA
Risco de valor	É a chance de que o valor de um ativo financeiro se altere de forma contrária ao que o investidor espera.	Por exemplo, se o valor de uma ação que você comprou diminuir, você sofre o perigo de valor (Lintner, 1965).	MARKOWITZ, Harry. Portfolio Selection. <b>The Journal of Finance</b> , v. 7, n. 1, mar. 1952
Risco de juros	É o risco associado às variações nas taxas de juros do mercado. Tendo como exemplo, se você tem títulos com juro fixo e as taxas de juros do mercado subirem, o valor de mercado dos seus títulos pode cair.	Cenário de Aumento das Taxas de Juros: Alguns meses após a compra, as taxas de juros do mercado para títulos de risco similares sobem para 12% ao ano. Novos títulos com taxa de juros de 12% ao ano ficam disponíveis no mercado. O valor de mercado do seu título original (com taxa de juros fixa de 10%) diminui. Se você precisar vender o título antes do vencimento, poderá ter que aceitar um preço menor do que R\$ 1.000, incorrendo em perdas (Lintner, 1965).	DIAS, Ricardo ; MURAKOSHI, Vivian Y. Fatores comuns de risco de mercado, tamanho, valor e diferenciais de juros nos retornos esperados das ações brasileiras. <b>Insper</b> , v. 195, p. 27, 2009.
Riscos Operacionais	São riscos que podem ser associados em atividades e processos internos de alguma organização que podem estar causando perdas financeiras, danos à reputação de alguma empresa ou de uma instituição financeira e (continua)	Falhas humanas, ou descumprimento de regulamentos. Desvios internos, atividades ilícitas praticadas por empregados ou falsificação de registros financeiros ou desvio de recursos da empresa para proveito pessoal (BIS, 2010).	ZHOU, Zhilong. Risk Evaluation, Analysis and Development Strategy of Real Estate Enterprises: Under the Background of New Normal Economy, Julho, 2020.

Quadro 1 — Revisão da literatura

(conclusão)

TIPO	ENTENDIMENTO	EXEMPLOS	REFERÊNCIA
Riscos Operacionais	(continuação) interrupções nas operações (Zhou, 2020). Eles são um tipo de perigo empresarial que foca em eventos internos, em contraste com os perigos financeiros, como variações nas taxas de moeda, ou perigos de mercado, como alterações nas condições econômicas (Zhou, 2020).		ZHOU, Zhilong. Risk Evaluation, Analysis and Development Strategy of Real Estate Enterprises: Under the Background of New Normal Economy, Julho, 2020.

Fonte: elaboração própria (2023).

## 2.2. Modelo de *score* de crédito

Segundo Elena Dumitrescu (2022), modelo de *score* de crédito trata-se de uma estratégia diferente combinada para avaliação de crédito denominada *Penalised Logistic Tree Regression* (PLTR) — “Regressão de Árvore Logística Penalizada”, em português. Esse modelo faz isso ao realizar pré-processamento dos dados, criando recursos adicionais com base em árvores de decisão de baixa complexidade, além de empregar uma técnica de penalização na estimativa. Isso é realizado mantendo intacta a capacidade do modelo de pontuação de ser interpretado de maneira intuitiva.

De maneira mais formal, o PLTR é composto por um modelo de regressão logística básico, que incorpora preditores originados a partir de árvores de decisão. Estes, por sua vez, correspondem a regras binárias, ou seja, folhas, geradas por árvores de decisão de profundidade limitada, construídas com base nas variáveis originais de previsão. O PLTR é uma técnica de aprendizado de máquina que mescla

elementos da regressão logística com a estrutura de árvores de decisão (Dumitrescu, 2022).

Essa abordagem é especialmente desenvolvida para aprimorar a capacidade de predição de variáveis-alvo, como aquelas aplicadas na avaliação de risco de inadimplência em situações, por exemplo, de concessão de crédito, em que o objetivo é avaliar a probabilidade de um indivíduo ou entidade não cumprir com suas obrigações financeiras (Dumitrescu, 2022).

### 2.2.1. Modelo PLTR

O modelo *Penalised Logistic Tree Regression* (PLTR) une a adaptabilidade característica das árvores de decisão para identificar relações intrincadas com a clareza da regressão logística, sendo tais conceitos:

- regressão logística é um método estatístico que analisa as relações entre variáveis dependentes e independentes, especialmente útil em problemas de classificação, como estimar se um cliente tem um risco alto ou baixo de não pagar um empréstimo;
- árvores de decisão são uma técnica de aprendizado de máquina que divide o espaço de características em regiões menores, baseada em condições lógicas, e eficientes na habilidade de detectar padrões complexos e relações não lineares nos dados; e
- penalização significa a aplicação de restrições nos parâmetros do modelo, com o objetivo de prevenir o sobreajuste (*overfitting*) e melhorar a capacidade de generalização.

Sendo assim, tal modelo cria árvores de decisão de baixa complexidade a partir das variáveis independentes originais e utiliza essas árvores para criar regras dicotômicas (nas folhas), que são integradas ao modelo de regressão logística. Em síntese, o modelo PLTR representa uma abordagem híbrida que combina a versatilidade das árvores de decisão com a interpretabilidade da regressão logística, tornando-o uma escolha eficaz para problemas de previsão de risco de crédito e outras tarefas de classificação (Dumitrescu, 2022).

### 2.2.2. Vantagens do modelo PLTR

A vantagem desse modelo reside na sua capacidade de abordar relações complexas entre os dados de forma mais eficaz do que a regressão logística tradicional, ao mesmo tempo que preserva a clareza inerente à regressão logística. Esse atributo é especialmente valioso em cenários em que é crucial compreender e justificar as decisões de concessão de empréstimo, como é o caso na previsão de riscos de crédito. Em suma:

- esse método nos permite capturar efeitos não lineares, ou seja, limites e interações entre as características, que podem estar presentes nos dados de pontuação de crédito;
- é amplamente reconhecido que os métodos de aprendizado de conjunto superam consistentemente a regressão logística, uma vez que esta última não é capaz de ajustar-se a esses efeitos não lineares;
- o aspecto notável da abordagem proposta reside em usar esses algoritmos para pré-processar os preditores, em vez de modelar diretamente a probabilidade padrão com algoritmos de classificação de aprendizado de máquina; e
- o PLTR fornece regras de pontuação que são econômicas e de fácil interpretação.

Foi demonstrado que o PLTR supera a regressão logística convencional em termos de precisão de previsão quando aplicado a dados que não fazem parte da amostra de treinamento. Além disso, ele apresenta um desempenho competitivo em comparação com o método de floresta aleatória, ao mesmo tempo em que oferece uma função de pontuação que é facilmente compreensível, visto que o método de floresta aleatória se beneficia da estrutura de divisão recursiva nas árvores de decisão, o que, por sua natureza, acomoda efeitos não lineares tanto univariados quanto multivariados não observados.

De fato, os especialistas em modelagem de risco de crédito frequentemente incorporam efeitos não lineares à regressão logística por meio de abordagens ad hoc ou heurísticas, bem como por meio de técnicas de engenharia de recursos (Benoit; Hurlin; Pérignon, 2019). Isso inclui ações como discretizar variáveis contínuas,

consolidar categorias e identificar não linearidades por meio de variáveis de interação cruzada.

De acordo com as pesquisas de Crook, Edelman e Thomas (2007), diversos tipos de modelos de risco de crédito têm sido desenvolvidos com o propósito de estimar a probabilidade de inadimplência (PD), a exposição ao risco de inadimplência (EAD) e as perdas em caso de inadimplência (LGD). Dentro desse conjunto de abordagens, os modelos de PD têm despertado grande interesse e se transformado em um foco central de estudo. Os modelos classificatórios são elaborados utilizando informações de crédito, visando criar um sistema de suporte à tomada de decisão que possa auxiliar os bancos na determinação dos pedidos de empréstimo que devem ser autorizados ou negados.

Além de explorar diversas técnicas de modelagem, numerosos estudos têm apresentado novos algoritmos com o intuito de aprimorar a acurácia na avaliação de crédito. Segundo Xia *et al.* (2018), a avaliação de crédito coletiva tende a se beneficiar da disponibilidade limitada de conjuntos de dados, o que é compreensível devido à dificuldade de acesso aos dados de crédito, a menos que sejam utilizados alguns conjuntos de dados públicos, como os conjuntos de dados de crédito alemães, australianos e japoneses disponíveis no repositório de aprendizado de máquina da UCI.

### 2.2.3. Desvantagens do modelo PLTR

O PLTR utiliza algoritmos de aprendizado de conjunto para pré-processar os preditores antes de modelar a probabilidade padrão. Isso pode adicionar uma camada de complexidade na implementação em comparação com métodos mais diretos como a regressão logística convencional (Benoit; Hurlin; Pérignon, 2019).

Outra desvantagem é a necessidade de expertise técnica. Como o PLTR emprega técnicas avançadas como floresta aleatória e outros algoritmos de aprendizado de máquina, pode requerer um nível mais alto de expertise técnica para ajustar adequadamente os modelos, interpretar os resultados e realizar a manutenção (Benoit; Hurlin; Pérignon, 2019).

Além disso, o uso de múltiplos algoritmos de aprendizado de máquina, especialmente em grandes conjuntos de dados, pode levar a um aumento significativo

nos custos computacionais, tanto em termos de tempo de processamento quanto de recursos necessários (Xia *et al.*, 2018).

Apesar de o PLTR oferecer regras de pontuação que são de fácil interpretação, em cenários onde modelos altamente interpretáveis são necessários, o uso de técnicas complexas de pré-processamento pode obscurecer a compreensão de como as entradas são transformadas em previsões (Xia *et al.*, 2018).

Há também, como desvantagem, a dependência de dados de qualidade. Como o PLTR e outros modelos baseados em aprendizado de máquina dependem fortemente da qualidade dos dados de entrada, qualquer limitação na disponibilidade ou na qualidade dos dados pode afetar negativamente a performance do modelo (Xia *et al.*, 2018).

### **2.3. Modelo Z-Score**

Outro modelo de *score* de crédito é o modelo Z-Score segundo o autor Edward I. Altman (2008). Por volta do início do novo milênio, os modelos de avaliação de crédito ganharam uma importância significativa devido às importantes diretrizes estabelecidas pelo novo Acordo de Basileia sobre a adequação de capital em relação ao risco de crédito que era conhecido como Basileia 2.

Notadamente os bancos e a maioria das instituições financeiras em escala global passaram a criar ou adaptar sistemas internos de gestão de risco de crédito. Esses esforços visam cumprir as práticas recomendadas para avaliar a probabilidade de inadimplência (PD) e, possivelmente, a perda em caso de inadimplência (LGD) em vários tipos de ativos de crédito.

O modelo Z-Score desenvolvido por Altman em 1968 emergiu como o principal modelo referência para uma das três abordagens fundamentais na definição das Probabilidades de Inadimplência (PDs). As outras duas abordagens compreendem a classificação de títulos em si ou técnicas baseadas na avaliação do mercado de capitais, como evidenciado pela metodologia de preços de opções do monitor de crédito, Modelo KMV, conhecido por determinar a probabilidade base de acordo com os preços dos ativos, fazendo uso das informações de mercado mais relevantes, que se concentra na frequência esperada de inadimplência (Santos; Santos, 2009). Essas

metodologias formam a base principal para a maioria dos modelos de Valor em Risco (VaR) relacionados a ativos de crédito.

Em resumo, pode se acreditar que se o modelo inicial de avaliação de crédito for robusto, construído com dados amplos e representativos, então o modelo de VaR de crédito terá a possibilidade de oferecer precisão e ser valioso na alocação de capital, tanto em termos regulatórios quanto econômicos. Caso contrário, não importa a complexidade dos dados quantitativos ou a sofisticação das estruturas analíticas de portfólio, pois não alcançarão resultados confiáveis na gestão do risco de crédito. Os opositores da análise discriminante argumentam que a maioria, ou possivelmente todos, os modelos financeiros que adotam essa técnica não cumprem vários requisitos estatísticos, tais como a premissa de normalidade multivariada e a independência das variáveis explicativas (Altman, 1968).

Embora essas sejam preocupações legítimas, a revisão bibliográfica indica que, ao definir criteriosamente certos índices para valores extremos, é possível mitigar em grande parte o desafio da normalidade. Além disso, testes contínuos de robustez dos modelos ao longo do tempo ajudarão a determinar a gravidade da violação da independência. O modelo Z-Score demonstrou ser resiliente o bastante para abranger tanto empresas de grande porte quanto pequenas. Uma vez definidos os grupos iniciais e selecionadas as empresas, os dados dos balanços e demonstrações de resultados foram coletados (Altman, 1968).

Considerando ampla gama de variáveis que podem ser indicativas de problemas empresariais, uma lista contendo vinte e dois índices potencialmente relevantes foi compilada para posterior avaliação. Esses índices foram categorizados em cinco grupos padrão, englobando aspectos de liquidez, lucratividade, alavancagem, solvência e atividade. A seleção desses índices baseou-se em sua popularidade na literatura e em sua possível relevância para o estudo, incluindo alguns índices "novos". Posteriormente, dentre os 22 índices originais, cinco foram destacados por apresentarem melhor desempenho na previsão de falência empresarial. A avaliação do conjunto completo de índices é contínua e, dado o caráter iterativo desse processo, não é possível afirmar que a função discriminante resultante seja ótima. Para chegar a um perfil final das variáveis, foram empregados os seguintes procedimentos (Altman, 1968), a saber:



- observação da significância estatística de diversas funções alternativas, incluindo determinação das contribuições relativas de cada variável independente;
- avaliação das intercorrelações entre as variáveis relevantes;
- observação da precisão preditiva dos diversos perfis; e
- julgamento do analista.

Observa-se que o modelo não inclui um termo constante (interceptação Y). Isso ocorre devido ao software específico utilizado, resultando na não padronização da nota de corte entre os dois grupos para zero. Muitos *softwares* estatísticos possuem um termo constante que ajusta a pontuação de corte para zero quando os tamanhos das amostras dos dois grupos são idênticos. X1, conhecido como Capital de Giro/Ativo Total (WC/AT), representa a relação entre o capital de giro e o total de ativos. Essa relação, comumente explorada em estudos empresariais, é uma medida dos ativos líquidos da empresa em relação à sua capitalização total.

Quando se considera a utilização do modelo Z-Score, a pergunta chave é: Como adaptar o modelo para ser utilizado nas empresas privadas? Profissionais como analistas de crédito, consultores para colocação privada, auditores contábeis e até mesmo as próprias empresas estão interessados na questão de que o modelo original só pode ser aplicado a entidades com ações negociadas publicamente devido à necessidade de dados sobre preços de ações para X4 (Altman, 2008).

### 2.3.1. Vantagens do modelo Z-Score

Uma das vantagens de se fazer uso do modelo Z-Score é a avaliação da solvência financeira, a qual permite avaliar a solvência e a probabilidade de falência de uma empresa. Isso é útil para investidores, credores e gestores na avaliação do risco associado a um investimento ou empréstimo.

O modelo Z-Score padroniza a avaliação financeira, facilitando a comparação entre diferentes empresas do mesmo setor ou de setores diversos, auxiliando na compreensão do desempenho relativo. Além disso, a indicação precoce de problemas financeiros pode sinalizar antecipadamente problemas financeiros, oferecendo um

alerta para a necessidade de mudanças ou intervenções na gestão financeira antes que a situação se agrave.

Outra vantagem deste modelo é que é relativamente simples de calcular e não requer informações confidenciais. Os componentes do modelo Z-Score geralmente são dados disponíveis nos relatórios financeiros.

A ampla aplicabilidade, por mais que tenha sido inicialmente desenvolvido para empresas públicas, também é um fato vantajoso, visto que o modelo Z-Score também pode ser adaptado e aplicado a empresas privadas com algumas modificações nos dados e abordagens, permitindo sua utilidade em diferentes contextos. Este modelo não é restrito a uma indústria específica, o que o torna aplicável em diferentes setores, desde manufatura até serviços, varejo, entre outros.

Por fim, é importante considerar que o modelo Z-Score não é infalível e tem suas limitações, como a dependência de dados precisos, a sensibilidade a mudanças econômicas e a incapacidade de prever eventos imprevisíveis que possam afetar a situação financeira de uma empresa (Altman; Sabato; Wilson, 2008).

### 2.3.2. Desvantagens do modelo Z-Score

Originalmente, o Z-Score foi desenvolvido para empresas públicas com ações negociadas, o que limita seu uso direto para empresas privadas ou não negociadas em bolsa, pois essas não têm todas as variáveis necessárias, como a volatilidade dos preços das ações, facilmente acessíveis (Altman, 2008).

O modelo pode ser excessivamente sensível a mudanças rápidas no ambiente econômico. Em períodos de alta volatilidade, o modelo pode não ser capaz de prever com precisão as falências devido à rápida mudança nas condições que afetam os indicadores financeiros usados na análise (Altman, 2008).

O modelo exige dados financeiros precisos e completos para ser eficaz. Em cenários onde a qualidade e a integridade dos dados financeiros são questionáveis, o modelo pode produzir resultados imprecisos (Altman, 2008).

O modelo presume que as variáveis usadas são normalmente distribuídas e independentes. Tal suposição pode não ser verdadeira na prática, o que pode levar a análises e previsões incorretas (Altman, 2008).

Tal modelo, também foca principalmente em dados financeiros quantitativos e não considera fatores externos como mudanças na gestão, competição, ou condições de mercado que podem impactar a performance da empresa (Altman, 2008). Enquanto a padronização facilita comparações, ela também pode ser uma desvantagem quando diferentes indústrias ou regiões possuem padrões contábeis distintos, o que pode levar a interpretações errôneas do Z-Score (Altman, 2008). Além disso, o Z-Score não se ajusta automaticamente com o tempo ou com mudanças nas práticas contábeis ou econômicas, sendo um modelo estático, necessitando de recalibrações periódicas para manter sua relevância e precisão (Altman, 2008).

#### **2.4. Riscos de crédito**

O risco de crédito, no jargão financeiro e de acordo com a Resolução do Banco Central do Brasil de n.º 4.557, de 23 de fevereiro de 2017, é a probabilidade de que um devedor não cumpra com suas obrigações de pagamento, causando prejuízos ao credor (Brasil, 2017). Esse risco está presente em diversas operações, como:

**Empréstimos:** quando um banco concede um empréstimo a um cliente, ele corre o risco de que este não pague as parcelas, gerando inadimplência.

**Financiamentos:** na compra de um imóvel ou carro financiados, a instituição financeira enfrenta o risco de que o cliente não quite as prestações, o que pode levar à retomada do bem.

**Cartões de crédito:** o uso do cartão de crédito também envolve risco de crédito, pois o credor (banco) adianta o valor das compras e espera ser ressarcido pelo cliente nas faturas seguintes.

**Operações entre empresas:** quando uma empresa vende produtos ou serviços para outra com pagamento a prazo, existe o risco de que a compradora não efetue o pagamento, gerando inadimplência comercial (Ueda, 2023).

O risco de crédito, anteriormente explorado, representa a possibilidade de perdas que uma instituição credora enfrenta em decorrência da inadimplência de um devedor. Para gerenciar esse risco de forma eficaz e tomar decisões de crédito mais assertivas, as instituições financeiras e empresas recorrem a modelos de risco de crédito. Esses modelos buscam analisar e quantificar a probabilidade de

inadimplência de um devedor, permitindo uma avaliação mais precisa do risco envolvido em cada operação de crédito.

## 2.5. Modelo de risco

O modelo de risco é uma ferramenta essencial no campo das finanças, utilizada para avaliar a probabilidade de eventos adversos e suas potenciais consequências econômicas. Esse modelo é fundamental para instituições financeiras, investidores e gestores de risco, pois permite identificar, mensurar e mitigar os diversos tipos de riscos aos quais uma entidade pode estar exposta. Entre os principais tipos de riscos financeiros, destacam-se o risco de crédito, o risco de mercado, o risco operacional e o risco de liquidez. Cada um desses riscos possui características próprias e requer abordagens específicas para sua gestão eficaz. O risco de crédito, em particular, é a possibilidade de que um devedor não cumpra com suas obrigações de pagamento, resultando em prejuízos para o credor. Esse risco está presente em diversas operações financeiras, como empréstimos, financiamentos e emissão de títulos de dívida. A gestão do risco de crédito envolve a análise da capacidade de pagamento do devedor, a diversificação das carteiras de crédito e a utilização de garantias e seguros para mitigar possíveis perdas (Ferreira, 2010).

### 2.5.1. Modelo de conjunto homogêneo

No âmbito do aprendizado de máquina, um modelo de conjunto homogêneo se refere a uma estratégia em que vários modelos do mesmo tipo ou pertencentes à mesma família de algoritmos são agrupados com o objetivo de aprimorar o desempenho global do modelo. Essa técnica é comumente empregada quando se busca aproveitar a variedade de modelos disponíveis para melhorar tanto a precisão das previsões quanto a habilidade de generalização do sistema (*bootstrap aggregating*, também conhecido como *bagging*).

A lógica subjacente à utilização desse conjunto de árvores de decisão semelhantes é que cada modelo pode apresentar suas próprias vantagens e desvantagens na categorização de diferentes categorias de e-mails. Tendo isso em

vista, ao integrar suas previsões, é possível minimizar a probabilidade de erros e obter uma classificação mais precisa.

### 2.5.2. Vantagens do modelo de conjunto homogêneo

Ao combinar as previsões de diversos modelos, o conjunto homogêneo diminui a influência de erros individuais e aumenta a precisão geral das previsões. Cada modelo pode ter seus pontos fortes e fracos, e o conjunto aproveita a diversidade para obter uma resposta mais robusta (Xia *et al.*, 2018).

A combinação de diferentes modelos reduz o *overfitting*, um problema comum em que o modelo se adapta excessivamente aos dados de treinamento, mas não se generaliza bem para novos dados. O conjunto homogêneo evita que um único modelo domine o processo, o que leva a um modelo mais flexível e adaptável a novas situações (Xia *et al.*, 2018).

Trabalhando com conjuntos homogêneos, são menos suscetíveis a ruídos nos dados e a *outliers*. Como cada modelo é treinado de forma independente, as previsões são menos afetadas por pontos discrepantes (Xia *et al.*, 2018).

Por fim, a implementação de conjuntos homogêneos é relativamente simples e pode ser feita com ferramentas de aprendizado de máquina populares (Xia *et al.*, 2018).

### 2.5.3. Desvantagens do modelo de conjunto homogêneo

Com o uso desse modelo, treinar e executar um conjunto de modelos pode ser mais caro computacionalmente do que treinar um único modelo. Isso pode ser um problema em aplicações onde o tempo de processamento é crítico (Lando, 2009). Além disso, a interpretação dos resultados de um conjunto homogêneo pode ser mais complexa do que a de um único modelo. Isso porque as previsões são uma combinação de diversos modelos, e não é fácil identificar qual modelo contribuiu mais para cada resultado (Lando, 2009).

Se os modelos do conjunto forem muito similares entre si, a vantagem da diversidade pode ser diminuída. É importante que os modelos tenham perspectivas diferentes sobre o problema para obter o máximo de benefício (Lando, 2009)

Por último, esse modelo possui como desvantagem o desempenho de um conjunto homogêneo, visto que depende da escolha do algoritmo utilizado para combinar as previsões dos modelos. Portanto, é de suma importância escolher um algoritmo que seja adequado ao problema e aos dados (Lando, 2009).

## **2.6. Modelo de conjunto heterogêneo**

Refere-se a uma estratégia em que diversos tipos de modelos de aprendizado de máquina são integrados com o intuito de aprimorar o desempenho global do sistema. Diferentemente dos modelos de conjunto homogêneos, nos quais todos os modelos são do mesmo tipo ou da mesma família de algoritmos, os modelos de conjunto heterogêneos fazem uso de uma diversidade de técnicas de aprendizado e algoritmos provenientes de diferentes famílias, a fim de explorar múltiplas perspectivas e abordagens para a resolução de um problema específico.

A principal vantagem de adotar um modelo de conjunto heterogêneo reside na sua diversidade. Cada modelo base possui suas próprias características positivas e negativas e, ao unir esses modelos, é possível atenuar as limitações de um com as capacidades dos demais (Ala'raj; Abbod, 2016).

Tal abordagem pode conduzir a previsões mais precisas e resilientes, especialmente em situações de aprendizado de máquina que envolvem desafios complexos. Há várias técnicas disponíveis para criar modelos de conjuntos heterogêneos. Uma delas é o *stacking* (empilhamento), que envolve a utilização de um modelo de nível superior para integrar as previsões dos modelos base. Outra abordagem é aplicar um sistema de "voto ponderado" para determinar a previsão final. É crucial fazer uma seleção criteriosa dos modelos base e ajustar seus hiperparâmetros de maneira apropriada para alcançar o melhor desempenho possível com o conjunto heterogêneo (Xia *et al.*, 2018).

Nos últimos tempos, tem-se observado um crescente interesse por um conjunto heterogêneo que combina as previsões de modelos base desenvolvidos por diferentes algoritmos de classificação. Esse conjunto tem se destacado de maneira notável em comparação com sua contraparte homogênea, demonstrando um desempenho superior. Além disso, Rokach, Schclar e Itach (2014), também investigaram essa

abordagem. No entanto, o modelo de conjunto heterogêneo atraiu recentemente muita atenção de pesquisas (Tsai; Hsu; Yen, 2014).

A ideia por trás do conjunto heterogêneo é que diferentes classificadores podem ver o mesmo padrão de maneira diferente, complementando assim a previsão um do outro. Fomos motivados a incorporar diversos classificadores individuais, bem como modelos de conjunto de alto desempenho, na composição do conjunto heterogêneo. Essa ação foi tomada com o intuito de aprimorar a habilidade de previsão do modelo proposto. Seguindo um processo de duas etapas principais, a maioria dos modelos de pontuação de crédito em conjunto constroem o conjunto de modelos e combinam os resultados. De acordo com as recomendações de Lessmann *et al.* (2015), destaca-se a relevância da estratégia de escolha do conjunto. Então, foi proposta uma etapa extra entre a formação do conjunto e a combinação dos resultados.

Assim, os principais desafios na aprendizagem em conjunto envolvem (1) o modo como os modelos básicos são criados, (2) o critério de seleção dos modelos básicos e (3) a forma de tomar as decisões mais adequadas (Xia *et al.*, 2018).

O modelo de conjunto homogêneo constitui uma variante do modelo de conjunto heterogêneo, empregando abordagens de conjunto tradicionais. Para avaliar o desempenho do modelo proposto e das referências, foram conduzidos testes nos quatro conjuntos de dados de crédito mencionados previamente, empregando quatro métricas de avaliação distintas. Foi realizada uma avaliação ampla e abrangente do modelo proposto, comparando-o minuciosamente com modelos de referência, que englobam os classificadores individuais, o modelo de conjunto homogêneo e o modelo de conjunto heterogêneo que emprega estratégias de conjunto convencionais. Ambos os modelos passam por uma validação rigorosa nos quatro conjuntos de dados de crédito do mundo real mencionados anteriormente, sendo avaliados por meio de quatro métricas de desempenho distintas (Lessmann *et al.*, 2015).

### 2.6.1. Vantagens do modelo de conjunto heterogêneo

Uma das vantagens do modelo de conjunto heterogêneo é a combinação de diferentes modelos com perspectivas distintas sobre o problema pode levar a previsões mais precisas e robustas. Cada modelo pode capturar diferentes aspectos

dos dados, e a combinação final reduz o *overfitting* e melhora a generalização do modelo (Lessmann *et al.*, 2015).

Modelos de conjunto heterogêneo são mais adequados para problemas complexos que não podem ser facilmente resolvidos por um único modelo. Ao combinar diferentes técnicas, o conjunto pode explorar diversas soluções e encontrar a melhor abordagem para o problema em questão (Lessmann *et al.*, 2015). A diversidade de modelos torna o conjunto mais resistente a ruído e dados ausentes nos dados de treinamento. Se um modelo for afetado por *outliers* ou dados faltantes, os outros modelos podem compensar essas falhas e fornecer uma previsão mais precisa (Lessmann *et al.*, 2015). Ademais, esses modelos são mais flexíveis e adaptáveis a diferentes tipos de dados e problemas. A escolha dos modelos base e dos métodos de combinação pode ser adaptada às características específicas do problema (Lessmann *et al.*, 2015).

#### 2.6.2. Desvantagens do modelo de conjunto heterogêneo

Assim como os outros modelos, o modelo de conjunto heterogêneo possui também desvantagens. A implementação e o gerenciamento de um modelo de conjunto heterogêneo podem ser mais complexos do que um modelo homogêneo. É preciso considerar a escolha dos modelos base, seus hiperparâmetros e os métodos de combinação, o que pode ser um desafio (Lessmann *et al.*, 2015).

Treinar e executar um conjunto heterogêneo pode ser mais computacionalmente caro do que um modelo homogêneo, especialmente se o conjunto envolver muitos modelos complexos (Lessmann *et al.*, 2015).

A interpretação dos resultados de um conjunto heterogêneo pode ser mais difícil do que a de um modelo homogêneo. Isso porque a previsão final é uma combinação de diferentes modelos, e não é fácil identificar qual modelo contribuiu mais para cada resultado (Lessmann *et al.*, 2015).

Além disso, o desempenho de um conjunto heterogêneo depende da escolha dos modelos base e dos métodos de combinação. Se os modelos base forem muito semelhantes ou se os métodos de combinação não forem adequados, o conjunto pode não apresentar um bom desempenho (Lessmann *et al.*, 2015).



## 2.7. OPEN FINANCE

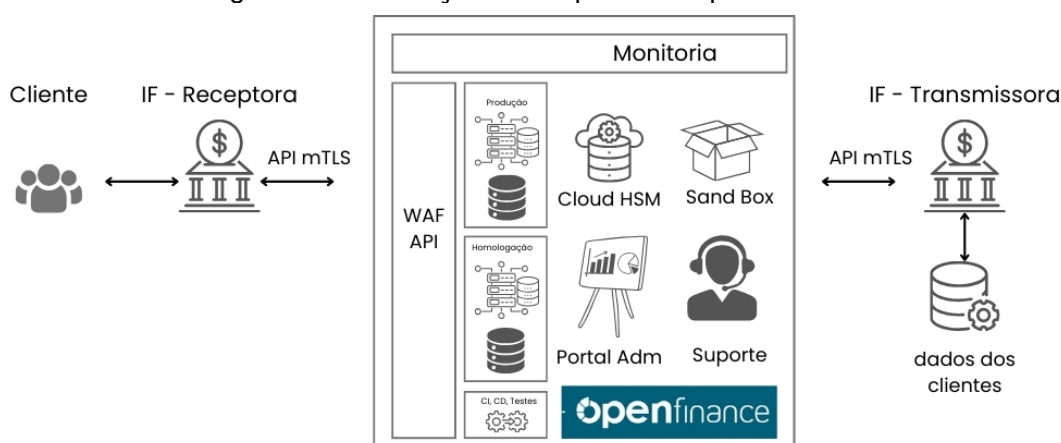
O Open Finance, ou Finanças Abertas, é um conceito revolucionário que está transformando o setor financeiro ao permitir um compartilhamento mais amplo e eficiente de informações entre diferentes instituições e serviços financeiros. Esse modelo promove uma maior integração e oferece aos consumidores o poder de gerenciar seus recursos financeiros de forma mais personalizada e eficiente (Dias, 2024).

O Open Finance é definido como um sistema que possibilita o compartilhamento de dados e serviços financeiros através de plataformas abertas e interoperáveis, com o consentimento explícito dos clientes. Esse sistema se baseia no princípio da transparência e na autonomia dos usuários sobre suas informações financeiras. Conforme a regulamentação estabelecida pelo Banco Central do Brasil (2021), o Open Finance é visto como um facilitador para a criação de um ambiente financeiro mais competitivo e inovador, proporcionando maior poder de escolha e de negociação para os usuários.

O funcionamento do Open Finance depende crucialmente de *application programming interfaces* (APIs). Essas interfaces permitem a integração segura e eficiente entre os sistemas das instituições financeiras e os aplicativos usados pelos consumidores. Dias (2024), descreve as APIs como "pontes" que garantem que os dados sejam compartilhados de forma segura, respeitando o consentimento do usuário. Essa tecnologia é fundamental para o sucesso do sistema de Open Finance, pois garante a privacidade e a segurança dos dados compartilhados.

O gráfico ilustrado pela Figura de 2 demonstra como as instituições financeiras fazem uso das APIs, para trocar as informações.

Figura 2 — Ilustração da Arquitetura Open Finance



Fonte: elaboração própria, 2024.

Um dos principais benefícios do Open Finance é a capacidade de personalizar os serviços financeiros oferecidos aos usuários. Eles ganham acesso a uma gama mais ampla de produtos e serviços, todos ajustados às suas necessidades individuais. Dias (2024), argumenta que isso não apenas melhora a experiência do usuário, mas também intensifica a competição entre as instituições financeiras, o que pode levar a taxas mais favoráveis e melhores condições de produtos financeiros para os consumidores.

No entanto, a implementação do Open Finance ainda é recente e por isso apresenta desafios significativos, especialmente no que diz respeito à segurança e à privacidade dos dados. O risco de acesso não autorizado a informações pessoais e financeiras é uma grande preocupação (Dias, 2024).

Segundo Fialho (2023), o Open Finance provoca um impacto profundo no mercado financeiro, exigindo constante inovação e adaptação das instituições tradicionais a esse novo cenário. Essa abertura beneficia novos participantes, como *fintechs* e *startups*, que podem competir em pé de igualdade com grandes bancos, graças à facilidade de acesso ao mercado proporcionada pelas APIs abertas.

Dessa forma, as perspectivas futuras para o Open Finance são amplamente otimistas. Antecipa-se que novas inovações continuarão a emergir, impulsionadas pela competitividade aumentada e pela demanda dos consumidores por serviços mais transparentes, eficientes e personalizados (Kobo, 2023).

Tendo isso em vista que o Open Finance não é apenas uma evolução tecnológica; ele representa uma oportunidade significativa para remodelar o

relacionamento entre consumidores e instituições financeiras, fomentando uma maior inclusão financeira e desenvolvimento econômico. Espera-se que a nova tecnologia seja o caminho para a remodelagem total dos serviços financeiros, além dos não financeiros, por meio de extensas personalizações e aproximação com os mais diversos públicos-alvo (Bacen, [s. d.]).

Ante o exposto, Open Finance é uma iniciativa que visa promover a interoperabilidade e a transparência no sistema financeiro, permitindo o compartilhamento seguro de dados entre instituições financeiras. Através de APIs padronizadas, os clientes podem autorizar o acesso às suas informações financeiras por parte de diferentes instituições, possibilitando uma análise mais ampla e precisa de seu perfil financeiro. Com orientações claras para implementação das APIs e fluxos de consentimento bem definidos, o Open Finance oferece um ambiente seguro e transparente para o compartilhamento de dados financeiros. Além disso, ao garantir a tempestividade dos dados compartilhados, as instituições podem contar com informações atualizadas em tempo real, possibilitando uma tomada de decisão mais eficiente e ágil (Bacen, [s. d.]).

### **3. PANORAMA REGULATÓRIO: LEGISLAÇÕES NACIONAIS E INTERNACIONAIS**

Este capítulo traz uma visão do ambiente regulatório brasileiro e europeu a respeito do compartilhamento de dados para análises financeiras. Esses temas se relacionam de maneira substancial ao trabalho, tendo em vista que a necessidade de concessão de crédito e demais operações financeiras movimentam o mercado consumidor, e possíveis jurisdições podem tornar as operações inviáveis economicamente, caso as instituições financeiras utilizem os dados de maneira insegura. Neste sentido, faz-se um panorama do ponto de situação atual desses temas no Brasil, de forma a direcionar o problema de compartilhamento de dados de maneira adequada.

#### **3.1. Panorama Brasil: Lei Geral de Proteção de Dados**

Algoritmos são séries pré-estabelecidas de comandos automatizados que, com base em dados pessoais e não pessoais, chegam a conclusões que podem submeter um indivíduo a uma determinada ação, que pode ou não ter impacto significativo na sua vida. Em sistemas mais complexos, como os que usam aprendizado de máquina, essas séries pré-estabelecidas podem ser modificadas de acordo com as variáveis usadas como base e pelas conclusões intermediárias (Monteiro, 2018).

Dessarte, há um complexo emaranhado de decisões, ora por aprendizado de máquinas, ora por inúmeros *inputs*, desde fórmulas matemáticas, até dados multivariados, que podem tornar intrincado a rastreabilidade de regras de negócio. Isso resulta que o humano possua garantia do uso em conformidade de seus dados (Monteiro, 2018).

Assim, o principal objetivo das leis de proteção de dados é regular o uso e o tratamento de dados pessoais. Elas buscam não apenas proteger a privacidade, mas também outros direitos fundamentais e liberdades individuais, que só podem ser exercidos na sua plenitude caso seja garantido a salvaguarda de informações pessoais por meio de um arcabouço seguro e confiável, protegendo direitos fundamentais (Monteiro, 2018).

Como se observa, o CDC e a Lei do Cadastro Positivo regulam o direito à explicação e à revisão de decisões automatizadas no âmbito das relações de consumo, mais especificamente quando envolvem a concessão de crédito e cálculo de risco de inadimplência. Mas essa proteção setorial é insuficiente, no entanto, em nenhum dos exemplos citados neste trabalho, os instrumentos de proteção consumerista seriam adequados. Daí a importância de previsões capazes de ampliar esses direitos para contextos mais diversos, on-line e off-line, envolvendo o uso de dados pessoais. Para esse fim, foi promulgada, no Brasil, a Lei n.º 13.709, de 14 de agosto de 2018, conhecida como a Lei Geral de Proteção de Dados (LGPD), que transpõe o sistema setorial de proteção nacional para um geral, que abrange o tratamento de dados pessoais, independente do contexto, setor e mercado (Monteiro, 2018).

O mandala ilustrada pela Figura de 3 mostra algumas das particularidades da LGPD.

Figura 3 — Elementos-chave de implantação da LGPD



Fonte: elaboração própria, 2024.

A LGPD melhora, harmoniza e integra um ecossistema de mais de quarenta normas setoriais que regulam, de forma direta e indireta, a proteção da privacidade e dos dados pessoais no Brasil. Foi baseada nas discussões que resultaram no Regulamento Geral sobre a Proteção de Dados (RGPD), que regula sobre a

privacidade e a proteção de dados pessoais de indivíduos na União Europeia (UE) e no Espaço Econômico Europeu, e tem por finalidade não somente dar às pessoas maior controle sobre os seus dados, mas também estimular um ambiente de desenvolvimento econômico e tecnológico, mediante regras flexíveis e adequadas para lidar com os mais inovadores modelos de negócio baseados no uso de dados pessoais. Isso inclui modelos de negócio que usam algoritmos para auxiliar na tomada de decisões automatizadas (Monteiro, 2018).

A LGPD também busca equilibrar interesses econômicos e sociais, garantindo a continuidade de decisões automatizadas e limitando abusos nesse processo, por meio da redução da assimetria de informações e, com isso, democratizando a relação entre setor privado e o Estado. Segundo Renato Leite Monteiro (2018), ao incluir dez princípios gerais de proteção de dados pessoais, a lei garante aos titulares dos dados o direito à transparência com “informações claras, precisas e facilmente acessíveis sobre a realização do tratamento e os respectivos agentes de tratamento, observados os segredos comercial e industrial”, conforme o artigo 6º (Brasil, 2018). Ou seja, a garantia para que se requirite aos órgãos públicos e privados informações sobre como os seus dados são usados.

Logo, o princípio da transparência da Administração Pública deve orientar toda e qualquer relação do responsável pelo tratamento de dados pessoais com o titular dos dados, assegurando a este o direito de acesso aos seus dados pessoais. Esse princípio também implica no dever de informar os critérios de tratamentos que são utilizados para finalidades comunicadas ao titular e o tratamento dado pela lei ao caso de pré-identificação de dados anonimizados (Monteiro, 2018).

Quando utilizados para composição de um perfil comportamental, dados dessa natureza poderão ser considerados como pessoais, desde que se refiram a uma pessoa identificada. De acordo com o artigo 12 da LGPD, dados anonimizados apenas serão considerados dados pessoais se houver reversão do processo de anonimização ao qual os dados foram submetidos — exclusivamente por meios próprios ou que, com esforços razoáveis, puderem ser revertidos — ou se eles se tratarem de dados utilizados para formar um perfil comportamental de determinada pessoa natural, se identificado (Brasil, 2018; Monteiro, 2018).

No entanto, a LGPD assegura aos indivíduos o direito de ter acesso a informações sobre que tipos de dados pessoais são usados para alimentar algoritmos

responsáveis por decisões automatizadas. Caso o processo automatizado tenha por objetivo formar perfis comportamentais ou use um perfil comportamental para tomar uma decisão posterior, essa previsão também abrangerá o acesso aos dados anonimizados usados para enriquecer tais perfis. Esse direito ainda abrange a possibilidade de conhecer os critérios usados para tomar a decisão automatizada e de pedir a revisão da decisão por um ser humano quando está afetando os interesses dos titulares (Monteiro, 2018).

A lei não proíbe revisões e tratamentos automatizados no tocante aos dados pessoais, seja no setor público ou privado. Isso dá ao titular dos dados pessoais instrumentos importantes para impedir abusos e práticas discriminatórias no uso dos seus dados. Tais direitos devem influenciar diretamente uma mudança na forma como produtos, serviços e processos são desenvolvidos, devido às obrigações de informar e explicar possíveis incidentes aos agentes de tratamento. Estes terão que pensar, desde o início, como garantir os direitos previstos na LGPD. Espera-se que isso reduza a obscuridade e a opacidade dos algoritmos (Monteiro, 2018).

A expansão das relações internacionais e o avanço de novos recursos tecnológicos aumentam a disputa entre as organizações, gerando preocupações sobre a proteção dos dados empresariais e de seus consumidores. Como demonstrado pelas revelações de áudios de empresas e dos principais órgãos do Brasil, as organizações e o governo estão mais expostos a espionagens ou invasões de hackers. Nesse contexto, é essencial que as empresas incorporem, em toda sua cadeia de produção e gestão princípios éticos, adequação de suas tecnologias e a proteção de seus dados, além de capacitação de seus colaboradores e estabeleçam uma relação de transparência em seu trabalho.

Em agosto de 2020, a LGPD entrou em vigor no Brasil, mas as sanções administrativas só foram aplicadas a partir de agosto de 2023. Esta lei traz uma série de desafios para as empresas, como a insegurança jurídica, a falta de conhecimento, o custo e a resistência cultural. Para mitigar esses desafios, as empresas devem investir em educação e conscientização, adotar medidas técnicas e organizacionais e elaborar um plano de adequação. O governo federal também deve promover a divulgação da lei, fornecer orientação às empresas e efetuar a fiscalização. A adequação à LGPD é um desafio, mas é essencial para proteger os dados pessoais dos cidadãos e das empresas (Rapôso *et al.*, 2019).

### 3.2. Panorama europeu: Regulamento Geral sobre a Proteção de Dados

O Regulamento Geral sobre a Proteção de Dados da União Europeia (RGPD) incorpora de maneira precisa as implicações que são associadas à analogia do petróleo, embora a metáfora não se encaixe de forma exata. O RGPD parte do pressuposto de que os dados pessoais têm um valor significativo, a ponto de cada etapa da manipulação desses dados demandar uma abordagem minuciosa e planejada. Embora o RGPD tenha sido estabelecido em 2016, a sua significância só ganhou destaque entre a maioria dos advogados em 2018, quando suas disposições entraram em vigor.

A mandala ilustrada pela Figura 4 demonstra algumas das características da RGPD.

Figura 4 — Elementos-chave de implantação da RGPD



Fonte: elaboração própria, 2024.

Na realidade, muitos dos requisitos do RGPD já estavam presentes em uma legislação anterior, a Diretiva de Proteção de Dados, porém possui uma implementação e conformidade deficientes. O RGPD capturou a atenção dos advogados e da comunidade empresarial devido à imposição de multas mínimas de oito dígitos e à criação de mecanismos internos e externos para reforçar os esforços de fiscalização. Por conseguinte, o RGPD representa o avanço regulatório mais



significativo na esfera da política de informação em uma era. O RGPD estabelece um ambiente regulatório complexo e defensivo para os dados pessoais. Entretanto, as ideias presentes no RGPD não são exclusivamente europeias nem inéditas. As garantias do RGPD podem ser identificadas, embora de maneira menos robusta e menos detalhada nas leis de privacidade dos Estados Unidos e nos compromissos da Comissão Federal de Comércio com empresas (Hoofnagle; Sloot; Borgesius, 2019).

### **3.3. Estratégias do Regulamento Geral sobre a Proteção de Dados**

O Regulamento Geral sobre a Proteção de Dados (RGPD), instituído pela UE em 2018, vai além de uma mera lei de privacidade, estabelecendo-se como um modelo abrangente de gestão de dados. As empresas são incentivadas a analisar cuidadosamente o ciclo de vida dos dados, desde a coleta até a eliminação, implementando medidas robustas de segurança e governança. Essa abordagem garante a proteção dos dados pessoais e o cumprimento das exigências do RGPD (Intersoft Consulting, [s. d.]).

O RGPD pode, em alguns casos, levar a um aumento no uso de dados pelas empresas. Isso se torna evidente principalmente em organizações que anteriormente não exploravam seus dados de forma intensiva. O regulamento, ao estabelecer regras claras para o tratamento de dados, ressalta a importância e o valor estratégico dessas informações, incentivando as empresas a utilizarem-nas de forma responsável e ética para alcançar seus objetivos (Intersoft Consulting, [s. d.]).

Além disso, o RGPD oferece uma oportunidade única para as empresas avaliarem o valor de seus dados. Ao implementar medidas de proteção e governança adequadas, os dados se transformam em um ativo estratégico, comparável ao valor de patentes ou direitos autorais. Essa mudança de perspectiva permite que as empresas explorem o potencial dos dados de forma mais eficiente, gerando novas oportunidades de negócio e vantagens competitivas (Intersoft Consulting, [s. d.]).

O regulamento também equipara a importância da privacidade às leis antitruste e às regulamentações sobre práticas corruptas no exterior, elevando-a a um nível crítico na cultura jurídica corporativa. Antes do RGPD, as violações de privacidade eram punidas com multas relativamente baixas, muitas vezes inferiores ao salário anual de um engenheiro iniciante. Com a implementação do Regulamento, as

empresas enfrentam penalidades mais severas, o que as provoca a levar a sério a proteção dos dados pessoais e a implementar medidas robustas de *compliance* (Intersoft Consulting, [s. d.]).

Os mecanismos de aplicação do RGPD, que incluem multas elevadas e a obrigatoriedade de notificar incidentes de segurança, visam dissuadir os executivos de minimizar violações de privacidade. A ampla definição de "violação" no RGPD leva as empresas a reportarem um maior número de incidentes de segurança, permitindo que as autoridades regulatórias identifiquem falhas e tomem medidas cabíveis. Essa abordagem proativa contribui para fortalecer a cultura de *compliance* e proteger os dados dos cidadãos europeus (Intersoft Consulting, [s. d.]).

Desde a sua introdução, o RGPD impulsionou significativamente a discussão sobre privacidade e dados pessoais nas empresas. Muitas organizações reavaliaram suas políticas de dados e, pela primeira vez, adotaram uma abordagem profissional e sistemática para o tratamento de informações pessoais. Essa mudança de postura demonstra o crescente reconhecimento da importância da proteção de dados e da necessidade de implementar medidas adequadas para garantir a conformidade com o RGPD (Intersoft Consulting, [s. d.]).

O RGPD estabelece diversas exigências para garantir a proteção dos dados pessoais. As empresas que lidam com esses dados devem implementar medidas de segurança robustas, realizar avaliações de impacto e nomear um Encarregado de Proteção de Dados (DPO). Além disso, é necessário obter o consentimento livre e expresso dos indivíduos para a coleta e uso de seus dados, fornecendo informações claras e transparentes sobre como esses dados serão utilizados (Intersoft Consulting, [s. d.]).

O impacto do RGPD se estende muito além das empresas que coletam e utilizam dados diretamente dos consumidores. O regulamento também se aplica a terceiros envolvidos na cadeia de tratamento de dados, como fornecedores de serviços e plataformas on-line. Isso significa que todas as empresas que lidam com dados pessoais de cidadãos europeus, mesmo que indiretamente, precisam estar em conformidade com as exigências do RGPD (Intersoft Consulting, [s. d.]).

Desde a aplicação do RGPD, fica evidente a evolução histórica da visão europeia sobre privacidade e proteção de dados. Inicialmente, a Europa reconheceu explicitamente a privacidade como um direito humano, expandindo suas garantias

além da proteção do lar para incluir salvaguardas para a vida familiar, comunicações, reputação e, posteriormente, adaptando-se à era da informação, incorporando a privacidade no contexto do processamento de dados. Ao contrário dos Estados Unidos, a legislação europeia aborda a questão da privacidade da informação como "proteção de dados" (Hoofnagle; Sloot; Borgesius, 2019).

Enquanto a proteção de dados enfatiza a justa utilização e o devido processo, a ideia de privacidade mantém a noção de uma vida privada, à maneira ateniense. Durante os anos 1970, surgiu uma discrepância crucial em relação à privacidade entre os EUA e a Europa. Enquanto os EUA adotaram as Práticas Justas de Informação (FIP) e aplicaram-nas de forma relevante apenas no setor governamental por meio do *Privacy Act* de 1974 e, no setor privado, especialmente no âmbito de relatórios de crédito, a Europa expandiu e aprofundou essas práticas, tornando-as obrigatórias para todas as formas de processamento de informações, tanto governamentais quanto comerciais (Hoofnagle; Sloot; Borgesius, 2019).

Em 1990, a Comissão Europeia receava que as divergências nas leis nacionais de proteção de dados impedissem o funcionamento adequado do mercado interno da UE, levando à proposição da Diretiva de Proteção de Dados, adotada em 1995. Contudo, surgiram desafios significativos com essa Diretiva. Houve dificuldades na harmonização das leis nacionais de privacidade e, mesmo entre os países comprometidos com a privacidade, a aplicação foi inconsistente, como evidenciado por multas pequenas, como a aplicada ao Facebook na França em 2017.

O RGPD, em contraste com a abordagem dos EUA, passou por um extenso processo político na UE, iniciado em 2009 e finalizado em 2016, quando foi oficialmente adotado e implementado em maio de 2018. Agora, a interpretação do RGPD está sob a responsabilidade dos tribunais, com diretrizes do recém-criado *European Data Protection Board*. O Tribunal de Justiça da União Europeia (TJUE) é a autoridade máxima para a interpretação da legislação da UE e tem proferido decisões expressivas em favor da privacidade (Hoofnagle; Sloot; Borgesius, 2019).

O RGPD tem a intenção de facilitar o fluxo livre de dados pessoais na UE para auxiliar as empresas, mas coloca uma ênfase notória na proteção das pessoas e de seus dados pessoais.

Portando, essa abordagem regula intensivamente as práticas de informações, especialmente aquelas realizadas por terceiros, e enfrenta desafios significativos

diante dos modelos de negócios baseados em *big data* e aprendizado de máquinas, pelo menos em sua forma atual (Hoofnagle; Sloot; Borgesius, 2019).

### **3.4. Aplicação do Regulamento Geral sobre a Proteção de Dados**

A aplicação do RGPD não é apenas uma exigência legal, mas também uma oportunidade para as empresas reforçarem a confiança com os consumidores, demonstrando compromisso com a segurança e a privacidade dos dados. À medida que entramos em uma era onde a informação é um dos ativos mais valiosos, a conformidade com o RGPD torna-se um elemento crucial para o sucesso empresarial e a integridade organizacional (UE, 2016).

#### **3.4.1. Dados pessoais e processamento**

O RGPD possui ampla gama de informações relativas a "dados pessoais" com rubrica identificável ou não. Isso inclui dados que identificam direta ou indiretamente uma pessoa, abrangendo não apenas informações pessoalmente identificáveis, mas também dados públicos ou não sensíveis. Então, define-se que o RGPD se aplica a qualquer operação realizada sobre dados pessoais, incluindo coleta, armazenamento, divulgação e exclusão.

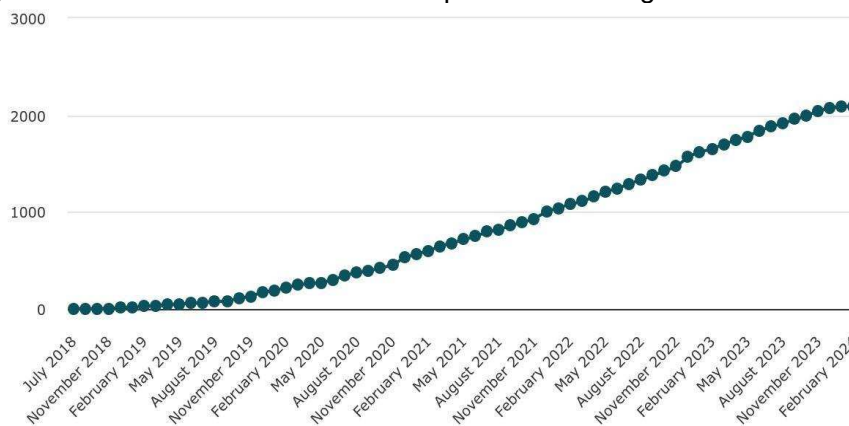
#### **3.4.2. Responsabilidades sob o Regulamento Geral sobre a Proteção de Dados**

O RGPD destina-se a assegurar uma gestão transparente e segura dos dados pessoais dos cidadãos da UE, impondo obrigações rigorosas às organizações que manuseiam esses dados. Este regulamento impacta tanto os controladores de dados, que definem os propósitos e meios de processamento, quanto os processadores, que realizam o processamento em nome dos controladores. As penalidades por não conformidade são severas e visam promover a proteção efetiva dos dados pessoais. O aumento recente nas multas aplicadas demonstra uma fiscalização mais rígida e a importância crescente de aderir às normas do RGPD. Agora, explorando mais sobre os "atores-chave" e suas responsabilidades sob o RGPD:

- Os atores-chave são: "titulares de dados", "controladores", "processadores" e "autoridades de proteção de dados".
- Os titulares de dados são as pessoas cujos dados pessoais são processados, enquanto os controladores determinam o propósito e os meios de processamento.
- Os processadores realizam operações com os dados em nome dos controladores.
- O RGPD responsabiliza os controladores pelo cumprimento das obrigações dos processadores e assegura que estes sejam competentes e responsáveis.

O gráfico ilustrado pela Figura 5 publicado na 5ª edição do relatório *GDPR Enforcement Tracker Report* de 2024, indica que ocorreu um aumento de quase 25% no quantitativo de multas aplicadas em decorrência do uso inadequado de dados pessoais em comparação com o mesmo período no ano de 2023, nos países partícipes da UE, denotando aumento substancial na temática de proteção e segurança dos dados.

Figura 5 — Número total de multas aplicadas ao longo de 2018 até 2024



Fonte: UE, 2024.

### 3.4.3. Extraterritorialidade do Regulamento Geral sobre a Proteção de Dados

O RGPD se aplica a dados processados fora da UE, caso estejam relacionados a indivíduos na UE. Mesmo sem presença física na UE, as empresas podem ser abrangidas pelo RGPD se oferecerem serviços para os cidadãos da UE. Além disso,

o regulamento orienta o comportamento de terceiros que monitoram o comportamento de pessoas na União Europeia.

#### 3.4.4. Exceções à aplicação do Regulamento Geral sobre a Proteção de Dados

O regulamento não se aplica a atividades puramente pessoais ou domésticas e não regula questões de segurança nacional e aplicação da lei, mas reconhece que o direito à proteção de dados pode conflitar com a liberdade de expressão. Certos direitos individuais podem ser limitados em casos específicos para salvaguardar outros direitos fundamentais ou interesses públicos.

Os modelos de risco podem ajudar as organizações a avaliarem e gerenciarem os riscos relacionados ao tratamento de dados, mas é essencial que qualquer modelo siga os princípios e requisitos da LGPD, no Brasil, e do RGPD, se a organização lida com dados de europeus. Os aspectos fundamentais que se encontram em ambos os modelos, para que sejam de acordo com as duas leis, LGPD e RGPD (Hoofnagle; Sloot; Borgesius, 2019), são:

- *consentimento e finalidade*, pois, para atuar com as informações pessoais, há necessidade de solicitar o consentimento das pessoas que as aprovem, e, além disso, a coleta de dados deve ter uma finalidade específica e o uso dos dados deve estar alinhado com essa finalidade;
- *minimização de dados*, uma vez que a coleta de dados deve ser limitada ao mínimo necessário para finalidade específica, evitando a coleta excessiva ou desnecessária;
- *segurança e proteção de dados*, já que as organizações são responsáveis por garantir a segurança e proteção de dados pessoais, implementando medidas técnicas e organizacionais para evitar segurança e vazamento; e
- *transparência e acesso*, visto que os titulares dos dados têm o direito de acessar informações pessoais próprias bem como de receber informações claras e transparentes sobre como seus dados são processados.

Essas metodologias podem incluir a avaliação de riscos, identificação de vulnerabilidades e ameaças, além da implementação de medidas para mitigar tais riscos. Os modelos de risco, sejam eles homogêneos (em que os riscos são tratados de forma semelhante) ou heterogêneos (em que os riscos são tratados de forma

variada e específica), podem ser usados pelas organizações para entender e gerenciar os riscos associados ao tratamento de dados e, os modelos devem preservar os princípios e diretrizes estabelecidas pela LGPD e pelo RGPD (Hoofnagle; Sloot; Borgesius, 2019).

#### 4. PROPOSTA DE *FRAMEWORK* DE RISCO DE CRÉDITO SEGURO

Este capítulo apresenta o *framework* de otimização de risco de crédito em consonância com o Open Finance e de acordo com a legislação correlata, viabilizado por meio de quadros com critérios mapeados baseados no Open Finance e da análise desses critérios de acordo com a LGPD. O processo de otimização envolve três etapas principais: organização da informação (1), diagnóstico de aderência (2) e validação jurídica (3).

Após a revisão da literatura, observou-se o problema que este trabalho visa solucionar. Não há uma norma universal ou guia prático que dite os padrões específicos para a construção de um *score* de crédito pelas instituições financeiras. Embora existam algumas diretrizes gerais e práticas comuns, a metodologia exata de como os *scores* de crédito são calculados pode variar significativamente entre diferentes credores e agências de crédito. Essa falta de uniformidade pode resultar em disparidades nos *scores* de crédito atribuídos aos consumidores, tornando o processo de avaliação de crédito menos transparente, assertivo e previsível. Idealmente, a implementação de uma norma ou guia padronizado poderia promover maior consistência e equidade no sistema de crédito, beneficiando tanto os credores quanto os consumidores.

Com a implementação do Open Finance, os credores têm a oportunidade de construir um *score* de crédito mais abrangente, seguro e preciso. Ao permitir o compartilhamento de dados entre instituições participantes, os clientes podem autorizar o acesso às suas informações cadastrais, transações bancárias e produtos de crédito contratados. Esses dados fornecem uma visão mais completa do comportamento financeiro do cliente, permitindo que as instituições avaliem com maior precisão seu perfil de crédito. Com a API de consentimento, o compartilhamento ocorre de forma segura e controlada, garantindo que seja feito apenas para finalidades específicas e por um período determinado. Além disso, os clientes têm o poder de revogar essa autorização a qualquer momento, proporcionando um maior controle sobre suas informações financeiras.

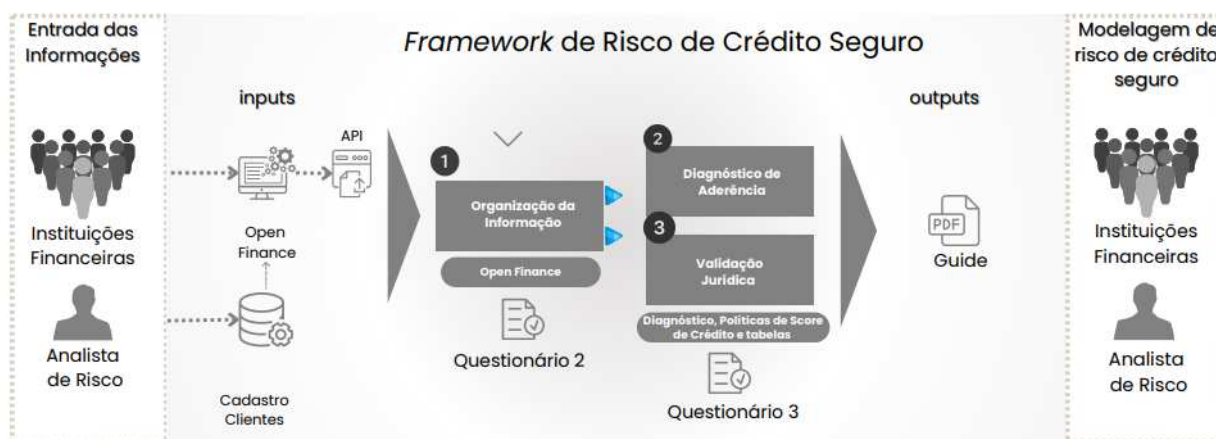
Dessa forma percebeu-se que há necessidade de um *framework* de risco de crédito seguro, fazendo uso das boas práticas do Open Finance e abarcando as exigências da LGPD, a ser seguido pelas instituições financeiras na construção de um



score de crédito mais seguro. A Figura 6 exibe um panorama geral da proposta de *framework*, composta de três etapas, onde serão descritos em detalhes nas seções seguintes. O trabalho examina em detalhes o conceito de *score* de crédito sobre os modelos citados na segunda parte do estudo e como assegurar a conformidade deles.

De acordo com a Figura 6, o objetivo da etapa de número um, conecta com a ausência de uniformidade nos métodos de classificação e organização da informação. Com isso, faz-se uso do Open Finance para solucionar essa fragilidade, pretendendo promover a interoperabilidade e a transparência no sistema financeiro.

Figura 6 — Fluxo de elaboração do *framework*



Fonte: elaboração própria (2023).

#### 4.1. Etapa 1: organização da informação

Esta etapa é necessária para o mapeamento dos questionamentos que devem ser adotados fazendo uso do Open Finance, representando os dados de entrada na organização da informação. Por meio dessa etapa, foram definidos os assuntos e critérios mais relevantes, carregando as informações constantes no Quadro 2, que apresenta perguntas relevantes para avaliação de riscos de crédito abarcado ao Open Finance, subdivididas em: organização, seções, aspecto e critérios, para servir como um guia inicial, na construção do *score* de crédito.

Quadro 2 — Critérios relevantes baseados no Open Finance

ORGANIZAÇÃO	SEÇÃO	ASPECTO	CRITÉRIO
<u>Consentimento</u>	A:Infraestrutura Organizacional	A1. Governança e viabilidade organizacional	A1.1 O cliente tem uma declaração explícita e detalhada do consentimento para compartilhamento de dados.
			A1.2 O cliente tem um plano formal para revogar o consentimento, se desejar.
			A1.3 O cliente tem o direito de escolher quais produtos específicos terão seus dados compartilhados.
			A1.4 O cliente pode especificar a origem precisa dos dados a serem compartilhados.
		A2. Estro	A2.1 O cliente tem acesso às políticas de privacidade e segurança relacionadas ao consentimento.
			A2.2 O cliente tem acesso às informações sobre como seus dados serão usados e protegidos.
		A3. Responsabilidade processual e estrutura política (documentação)	A3.1 O cliente é informado sobre como os dados serão armazenados e protegidos a longo prazo.
			A3.2 O cliente tem conhecimento sobre os custos associados ao compartilhamento de dados.
		A4. Sustentabilidade financeira	A4.1 O cliente é informado sobre quaisquer contratos ou acordos que regem o compartilhamento de dados.

Quadro 2 — Critérios relevantes baseados no Open Finance

(continuação)

ORGANIZAÇÃO	SEÇÃO	ASPECTO	CRITÉRIO
<u>Consentimento</u>	A: Infraestrutura Organizacional	A4. Sustentabilidade financeira	A4.2 O cliente entende seus direitos e responsabilidades ao consentir para o compartilhamento de dados
		A5. Contratos, licenças e responsabilidades.	.
<u>Cartão de Crédito</u>	B: Consentimento	B1. Modelo	B1.1 O cliente autoriza o compartilhamento de todos os recursos selecionados.
			B1.2 Conta Cartão ativa em um período de até 12 meses anterior ao início da vigência do consentimento
			B1.3 Conta Cartão cancelada/encerrada em um período de até 12 meses anterior ao início da vigência do consentimento.
		B2. Recursos passíveis de confirmação	B2.1 Conta Cartão que não está efetivamente ativa e visível nos canais eletrônicos.
B2.2 Conta Cartão cancelado/encerrada em um período maior que 12 meses anterior ao início da vigência do consentimento.			

Quadro 2 — Critérios relevantes baseados no Open Finance

(continuação)

ORGANIZAÇÃO	SEÇÃO	ASPECTO	CRITÉRIO
<u>Cartão de Crédito</u>	B: Consentimen- to	B2. Recursos passíveis de confirmação	B2.3 Conta Cartão que pertence a clientes sob bloqueio que implica em indisponibilidade do produto no canal eletrônico.
		B3. Recomendações do uso de <i>polling</i>	B3.1 Implementar um <i>retry</i> exponencial para evitar sobrecarregar a API de Recursos
		B4. Diagrama representacional de st.	B4.1 Representa os status da API de Recursos ao longo do tempo em relação aos recursos de cartões.
		B5. Comportamento da API de Cartão de Crédito	B5.1 Define como a API de Cartão de Crédito deve responder com base nos status dos recursos.
		B6. Casos de uso de contas cartões	B6.1 Define os diferentes cenários em que as contas de cartão podem estar e seus status correspondentes.
		B7. Regras quanto a interpretação pelos receptores do status da API Recursos	B7.1 Estabelece como as instituições receptoras devem interpretar os status da API Recursos.
		B8. Regras de busca na API Recursos	B8.1 Define as melhores práticas para a consulta da API Recursos para obter os status dos recursos de cartão de crédito.

Quadro 2 — Critérios relevantes baseados no Open Finance

(continuação)

ORGANIZAÇÃO	SEÇÃO	ASPECTO	CRITÉRIO
<p><u>Investimento</u></p>	<p>C: Tempestividade dos dados para APIs</p>	<p>C1: Limite de tempo para atualização</p>	<p>C1.1 Até uma hora para as APIs Renda Fixa Bancária, Renda Fixa Crédito, Títulos do Tesouro Direto e Fundos de Investimento; Para a API Renda Variável, posição e movimentações do fechamento do dia anterior (d-1).</p>
	<p>D: Visão da API de Recursos</p>	<p>D1. Identificador único</p>	<p>D1.1 O resourceId (recurso) corresponde ao investmentId (investimento) nas APIs de Investimentos.</p>
	<p>E: Regras de Negócio</p>	<p>E1. Código e descrição das regras</p>	<p>E1.1 RN001: Retorno obrigatório do identificador único para todos os recursos de investimento; RN002: Atualização do status para UNAVAILABLE após 12 meses de resgate, vencimento, transferência de custódia ou titularidade; RN003: Recomendação de polling para situações de preparação da listagem de recursos; RN004: Compartilhamento de todos os investimentos elegíveis; RN005: Status PENDING_AUTHORISATION para investimentos em múltiplas alçadas; RN006: Listagem de investimentos disponíveis apenas com status AVAILABLE; RN007: Tratamento independente de status para cada recurso autorizado; RN008: Retorno de lista vazia para clientes sem operações de investimento.</p>

Quadro 2 — Critérios relevantes baseados no Open Finance

(conclusão)

ORGANIZAÇÃO	SEÇÃO	ASPECTO	CRITÉRIO
<u>Investimento</u>	F: Recomendação do uso de <i>polling</i>	F1. Estratégia de consulta	F1.1 Implementação de retry exponencial para evitar sobrecarga na API de Recursos.
	G: Diagrama representacional do status	G1. Status dos recursos ao longo do tempo	
	H: Casos de uso de Investimentos	H1. Status esperado dos recursos	H1.1 Diferentes cenários de investimentos e seus respectivos status: AVAILABLE, UNAVAILABLE, PENDING_AUTHORISATION, TEMPORARILY_UNAVAILABLE.
	I: Regras de interpretação do status	I1. Ações baseadas nos status	I1.1 Interpretação dos status PENDING_AUTHORISATION, AVAILABLE, UNAVAILABLE, TEMPORARILY_UNAVAILABLE e suas recomendações de ação.
	K: Definição das regras de compartilhamento	K1. Escopo do compartilhamento	K1.1 Detalha os recursos elegíveis e não elegíveis para compartilhamento, incluindo critérios como período de vigência e bloqueios.

Fonte: elaboração própria (2023).

#### 4.2. Etapa 2: diagnóstico de aderência

Já o objetivo da segunda etapa, seguindo o Quadro 2, é de correlacionar os critérios da Open Finance com as exigências da LGPD, visando à aderência à norma. Ao fazer o cruzamento dessas informações, a criação de tabela possibilitará mais clareza e melhor avaliação de riscos e garantia à proteção de dados dos consumidores. Essa iniciativa é essencial para garantir que o *framework* proposto se aproveite das questões e critérios do Open Finance e seja implementado de forma

segura e eficaz, respeitando as normas de proteção de dados e fortalecendo a confiança no sistema financeiro aberto.

A seguir, o Quadro 3 apresenta uma análise entre os itens da LGPD comparados aos critérios baseados no Open Finance, dando maior visibilidade e aplicabilidade, de acordo com itens importantes, das possíveis melhorias que podem ser adotadas pelas instituições financeiras.

Quadro 3 — Análise dos itens da LGPD vs. critérios baseados no Open Finance

ITEM DE ANÁLISE	LGPD	OPEN FINANCE
O cliente tem uma declaração explícita e detalhada do consentimento para compartilhamento de dados.	Art. 7º, VII - Princípio da segurança: Utilização de medidas técnicas e administrativas aptas a proteger os dados pessoais de acessos não autorizados e de situações acidentais ou ilícitas de destruição, perda, alteração, comunicação ou difusão.	Seção A.A1.1 - O compartilhamento de dados só pode ser realizado mediante o consentimento expresso do cliente. O consentimento deve ser livre, específico, informado e inequívoco, manifestando-se por meio de declaração ou atitude afirmativa, podendo ser revogado a qualquer tempo.
O cliente tem um plano formal para revogar o consentimento, se desejar.	Art. 8º - O direito do titular revogar o consentimento.	Seção A.A1.2: O cliente tem o direito de revogar o seu consentimento a qualquer tempo, mediante comunicação direta à instituição financeira. A revogação do consentimento não afeta o tratamento de dados realizado anteriormente com base em consentimento válido.
O cliente tem o direito de escolher quais produtos específicos terão seus dados compartilhados.	Art. 9º - Direito ao Acesso Facilitado às Informações	Seção A.A1.3 - As instituições financeiras devem fornecer informações claras e acessíveis sobre os produtos e serviços que oferecem, incluindo os dados que são coletados e compartilhados.

Quadro 3 — Análise dos itens da LGPD vs. critérios baseados no Open Finance

(continuação)

ITEM DE ANÁLISE	LGPD	OPEN FINANCE
O cliente tem acesso às políticas de privacidade e segurança relacionadas ao consentimento.	Art. 46 - Medidas de Segurança	Seção A.A2.1 - As instituições financeiras devem implementar medidas de segurança adequadas para proteger os dados dos clientes contra acessos não autorizados, uso indevido, divulgação, alteração ou destruição.
O cliente tem acesso às informações sobre como seus dados serão usados e protegidos.	Art. 47 - Garantia da Segurança da Informação	Seção A.A2.2 - As instituições financeiras devem fornecer informações claras e acessíveis sobre como os dados dos clientes serão utilizados.
O cliente é informado sobre como os dados serão armazenados e protegidos a longo prazo.	Art. 48 - Comunicação de Incidente de Segurança	Seção A.A3.1 - As instituições financeiras devem implementar mecanismos de governança de dados para garantir o uso adequado e seguro dos dados dos clientes.
O cliente é informado sobre quaisquer contratos ou acordos que regem o compartilhamento de dados.	Art. 49 - Requisitos de Segurança dos Sistemas	Seção A.A3.2 - As instituições financeiras só podem compartilhar dados com outras instituições mediante autorização expressa do cliente e com a observância dos requisitos da LGPD.
O cliente autoriza o compartilhamento de todos os recursos selecionados.	Art. 7º - Consentimento do titular do dado pessoal	Seção B.B1.1 - Consentimento do cliente para compartilhamento de dados financeiros.



Quadro 3 — Análise dos itens da LGPD vs. critérios baseados no Open Finance

(continuação)

ITEM DE ANÁLISE	LGPD	OPEN FINANCE
Conta Cartão ativa em um período de até 12 meses anterior ao início da vigência do consentimento.	Art. 8º - Direito do titular revogar o consentimento	Seção B.B1.2 - Direito do cliente de revogar o consentimento em até 12 meses.
Conta Cartão cancelado/encerrada em um período de até 12 meses anterior ao início da vigência do consentimento.	Art. 9º - Direito ao Acesso Facilitado às Informações	Seção B.B1.3 - Direito do cliente ao acesso facilitado às informações sobre contas canceladas nos últimos 12 meses.
Conta Cartão que não está efetivamente ativa e visível nos canais eletrônicos.	Art. 10º - Retificação de dado incompleto, inexato ou desatualizado	Seção B.B2.1 - Direito do cliente à retificação de dados incompletos, inexatos ou desatualizados, incluindo contas não ativas ou visíveis eletronicamente.
Conta Cartão que pertence a clientes sob bloqueio que implica em indisponibilidade do produto no canal eletrônico.	Art. 12º - Eliminação dos dados pessoais tratados com o consentimento do titular	Seção B.B2.3 - Direito do cliente à eliminação dos dados pessoais tratados com seu consentimento, incluindo contas bloqueadas que não estão disponíveis nos canais eletrônicos.
Implementar um <i>retry</i> exponencial para evitar sobrecarregar a API de Recursos.	Art. 46 - Medidas de Segurança	Seção B.B3.1 - Implementação de medidas de segurança para evitar sobrecarga nos sistemas de Open Finance ao consultar recursos financeiros.

Quadro 3 — Análise dos itens da LGPD vs. critérios baseados no *Open Finance*  
(continuação)

ITEM DE ANÁLISE	LGPD	OPEN FINANCE
Representa os status da API de Recursos ao longo do tempo em relação aos recursos de cartões.	Art. 47 - Garantia da Segurança da Informação	Seção B.B4.1 - Garantia da segurança da informação ao representar os status dos recursos de cartões de forma apropriada ao longo do tempo.
Define como a API de Cartão de Crédito deve responder com base nos status dos recursos.	Art. 48 - Comunicação de Incidente de Segurança	Seção B.B5.1 - Comunicação de incidentes de segurança relacionados à API de Cartão de Crédito e seus recursos.
Define os diferentes cenários em que as contas de cartão podem estar e seus status correspondentes.	Art. 49 - Requisitos de Segurança dos Sistemas	Seção B.B6.1 - Estabelecimento dos requisitos de segurança dos sistemas para lidar com diferentes cenários de contas de cartão e seus respectivos status.
Até uma hora para as APIs Renda Fixa Bancária, Renda Fixa Crédito, Títulos do Tesouro Direto e Fundos de Investimento; Para a API Renda Variável, posição e movimentações do fechamento do dia anterior (d-1).	Art. 7º - Consentimento do titular do dado pessoal	Seção C.C1.1 - Requisitos de tempo para atualização de informações financeiras em APIs específicas, garantindo acesso rápido e atualizado aos dados de investimento.
O resourceId corresponde ao investmentId nas APIs de Investimentos.	Art. 8º - Direito do titular revogar o consentimento	Seção D.D1.1 - Padronização de identificadores únicos para recursos de investimento em APIs de investimentos.

Quadro 3 — Análise dos itens da LGPD vs. critérios baseados no Open Finance

(continuação)

ITEM DE ANÁLISE	LGPD	OPEN FINANCE
<p>RN001: Retorno obrigatório do identificador único para todos os recursos de investimento; RN002: Atualização do status para UNAVAILABLE após 12 meses de resgate, vencimento, transferência de custódia ou titularidade; RN003: Recomendação de polling para situações de preparação da listagem de recursos; RN004: Compartilhamento de todos os investimentos elegíveis; RN005: Status PENDING_AUTHORIZATION para investimentos em múltiplas alçadas; RN006: Listagem de investimentos disponíveis apenas com status AVAILABLE; RN007: Tratamento independente de status para cada recurso autorizado; RN008: Retorno de lista vazia para clientes sem operações de investimento.</p>	<p>Art. 9º - Direito ao Acesso Facilitado às Informações</p>	<p>Seção E.E1.1 - Regras de negócio para manipulação e compartilhamento de informações de investimentos, incluindo requisitos de status, atualizações e tratamento de dados para diferentes situações.</p>

Quadro 3 — Análise dos itens da LGPD vs. critérios baseados no Open Finance  
(conclusão)

ITEM DE ANÁLISE	LGPD	OPEN FINANCE
Representa o status dos recursos de investimento em relação ao período de vigência do consentimento.	Art. 47 - Garantia da Segurança da Informação	Seção G.G1.1 - Garantia de acesso facilitado às informações sobre o status dos recursos de investimento durante o período de vigência do consentimento do cliente.
Diferentes cenários de investimentos e seus respectivos status: AVAILABLE, UNAVAILABLE, PENDING_AUTHORIZATION, TEMPORARILY_UNAVAILABLE.	Art. 49 - Requisitos de Segurança dos Sistemas	Seção H.H1.1 - Definição dos possíveis cenários de investimentos e os estados correspondentes, incluindo disponibilidade, não disponibilidade e status de autorização pendente, para garantir a segurança e integridade das informações de investimento.

Fonte: elaboração própria (2023).

### 4.3. Etapa 3: validação jurídica

Esta importante etapa ocorre em paralelo com a etapa 2, onde o *framework* toma como alicerce principal a LGPD, garantindo a proteção dos dados pessoais dos usuários por empresas privadas ou públicas. O *framework* resultado desse trabalho auxiliará aos modelos de *score* de crédito. A lei proíbe o tratamento de dados pessoais com base nos seguintes critérios discriminatórios:

- *legitimidade*, os dados pessoais devem ser utilizados para finalidades legítimas, como concessão de empréstimos ou avaliação de crédito;
- *transparência*, as empresas privadas ou públicas devem ser transparentes sobre como os dados são coletados, usados e compartilhados;
- *consentimento*, os dados obtidos necessitam do consentimento dos indivíduos antes de sua coleta ou uso;
- *segurança*, é necessário proteger os dados contra acesso não autorizado, uso indevido, divulgação, alteração ou destruição; e

- *direitos dos indivíduos*, as empresas públicas ou privadas devem respeitar os direitos dos indivíduos de acessar, corrigir ou excluir seus dados.

Além disso, o *framework* propõe práticas para garantir que os modelos não utilizem dados discriminatórios. Por exemplo, em vez de usar dados pessoais sensíveis como raça, os modelos devem se basear em informações como histórico de crédito, renda, emprego e educação. Dessa forma, evita-se qualquer violação da LGPD e assegura-se um tratamento justo e ético dos dados pessoais.

O *framework* objetiva equilibrar a inovação e a personalização dos serviços financeiros com a proteção dos dados pessoais dos consumidores. A estrutura não só eleva a confiança dos consumidores em serviços financeiros, mas também ajuda as instituições a se manterem competitivas e em conformidade com as normas. A interação entre reguladores, instituições financeiras, analista de riscos e especialistas em tecnologia é essencial para o sucesso e a sustentabilidade dessas práticas, a seguir, será apresentado, no Quadro 4, o *framework* com as melhores práticas de montagem de *score* de crédito, com as questões mais relevantes de acordo com os estudos abarcados anteriormente nos Quadros 2 e 3, sendo compostas das colunas TC (Totalmente Compatível), PC (Parcialmente Compatível), NC (Não Compatível) e N/A (Não se Aplica), sendo feita a validação de cada item de acordo com os modelos de *score* de crédito.

Quadro 4 — *Framework* proposto

<b>PRÁTICAS PARA MONTAGEM DO SCORE DE CRÉDITO</b>	<b>NORMA/LEI REFERÊNCIA</b>	<b>TC</b>	<b>PC</b>	<b>NC</b>	<b>N/A</b>
1. Quais são os objetivos específicos do <i>score</i> de crédito que estamos tentando alcançar?	LGPD. Art. 7º/OP. Seção A. Item A1.3				
2. Quais são as variáveis-chave que devem ser consideradas na avaliação do risco de crédito?	LGPD. Art. 9º/OP. Seção B. Item B2.1				

Quadro 4 — *Framework* proposto

(continuação)

PRÁTICAS PARA MONTAGEM DO SCORE DE CRÉDITO	NORMA/LEI REFERÊNCIA	TC	PC	NC	N/A
3. Onde podemos obter dados históricos relevantes sobre o comportamento de crédito dos indivíduos?	LGPD. Art. 49/ OP. Seção A. Item A1.3				
4. Como podemos garantir que os dados coletados estejam padronizados e prontos para análise?	LGPD. Art. 46 / OP. Seção A. Item A2.1				
5. Qual algoritmo de modelagem é mais adequado para criar o <i>score</i> de crédito desejado?	LGPD. Art. 49 / OP. Seção A. Item A3.1				
6. Como devemos dividir os dados para treinar e testar o modelo de <i>score</i> de crédito?	LGPD. Art. 49 / OP. Seção A. Item A3.1				
7. Quais ajustes precisam ser feitos no modelo para garantir que ele se ajuste bem aos dados de treinamento?	LGPD. Art. 10º / OP. Seção B. Item B3.1				
8. Como podemos verificar se o modelo de <i>score</i> de crédito é eficaz em prever o risco em novos dados?	LGPD. Art. 7º/ OP. Seção G. Item G1.1				
9. Quais métricas de desempenho devemos usar para avaliar a precisão e a robustez do <i>score</i> de crédito?	LGPD. Art. 9º / OP. Seção G. Item G1.1				
10. Quais são os sistemas ou processos que utilizam o <i>score</i> de crédito para tomar decisões?	LGPD. Art. 49 / OP. Seção G. Item G1.1				
11. Com que frequência devemos atualizar o modelo de <i>score</i> de crédito para garantir sua relevância contínua?	LGPD. Art. 46 / OP. Seção B. Item B4.1				

Quadro 4 — *Framework* proposto

(conclusão)

<b>PRÁTICAS PARA MONTAGEM DO SCORE DE CRÉDITO</b>	<b>NORMA/LEI REFERÊNCIA</b>	<b>TC</b>	<b>PC</b>	<b>NC</b>	<b>N/A</b>
12. Como podemos garantir que o <i>score</i> de crédito seja transparente e compreensível para os usuários?	LGPD. Art. 7º / OP. Seção B. Item B6.1				
13. Quais medidas estamos tomando para proteger os dados pessoais dos indivíduos durante o processo?	LGPD. Art. 46 / OP. Seção A. Item A2.1				
14. Como estamos garantindo que o <i>score</i> de crédito não esteja discriminando injustamente certos grupos de pessoas?	LGPD. Art. 7º / OP. Seção B. Item B3.1				
15. Os clientes têm a oportunidade de contestar ou corrigir informações em seus <i>scores</i> de crédito?	LGPD. Art. 9º / OP. Seção B. Item B1.3				

Fonte: elaboração própria (2023).

## 5. RESULTADOS: VALIDAÇÃO E APLICAÇÃO DO *FRAMEWORK*

A análise e a validação do *framework* proposto, deve seguir de acordo com os modelos de *score* de crédito PLTR, Z-Score e os modelos de risco de conjunto homogêneo e heterogêneo. Cada um desses modelos traz uma abordagem única para a análise de crédito, contribuindo para uma avaliação mais abrangente e precisa da capacidade de crédito dos usuários. Os modelos foram avaliados de forma individual, analisando-se todos os quinze itens apontados pelo *framework*, verificando aderência conforme as colunas TC (Totalmente Compatível), PC (Parcialmente Compatível), NC (Não Compatível) e N/A (Não se Aplica). Com isso, espera-se apontar as possíveis fragilidades de cada modelo e onde pode-se aplicar melhorias na busca de maior conformidade com a norma legal.

Observa-se primeiramente o modelo PLTR, abordagem híbrida que combina as árvores de decisão com a regressão logística para melhorar a previsão e interpretação em problemas de classificação. Além disso, o PLTR oferece vantagens em termos de interoperabilidade e ajuste a dados não lineares, superando métodos tradicionais e outros algoritmos de aprendizado de máquina, como a floresta aleatória, em precisão de previsão, particularmente em dados fora da amostra de treinamento. Esse modelo também usa árvores de decisão de baixa complexidade para criar regras dicotômicas, que são integradas ao modelo de regressão logística. Essa integração permite ao PLTR capturar relações complexas e efeitos não lineares nos dados mais eficazmente do que a regressão logística convencional.

O Quadro 5 apresenta a validação e aderência do modelo PLTR de acordo com o *framework* proposto neste trabalho.

Quadro 5 — Validação do modelo PLTR de acordo com o *framework*

PRÁTICAS PARA MONTAGEM DO <i>SCORE</i> DE CRÉDITO	NORMA/LEI REFERÊNCIA	TC	PC	NC	N/A
1.Quais são os objetivos específicos do <i>score</i> de crédito que estamos tentando alcançar?	LGPD. Art. 7º/OP. Seção A. Item A1.3		✓		



Quadro 5 — Validação do modelo PLTR de acordo com o *framework*  
(continuação)

PRÁTICAS PARA MONTAGEM DO SCORE DE CRÉDITO	NORMA/LEI REFERÊNCIA	TC	PC	NC	N/A
2. Quais são as variáveis-chave que devem ser consideradas na avaliação do risco de crédito?	LGPD. Art. 9º/ OP. Seção B. Item B2.1	✓			
3. Onde podemos obter dados históricos relevantes sobre o comportamento de crédito dos indivíduos?	LGPD. Art. 49/ OP. Seção A. Item A1.3	✓			
4. Como podemos garantir que os dados coletados estejam padronizados e prontos para análise?	LGPD. Art. 46 / OP. Seção A. Item A2.1		✓		
5. Qual algoritmo de modelagem é mais adequado para criar o <i>score</i> de crédito desejado?	LGPD. Art. 49 / OP. Seção A. Item A3.1		✓		
6. Como devemos dividir os dados para treinar e testar o modelo de <i>score</i> de crédito?	LGPD. Art. 49 / OP. Seção A. Item A3.1		✓		
7. Quais ajustes precisam ser feitos no modelo para garantir que ele se ajuste bem aos dados de treinamento?	LGPD. Art. 10º / OP. Seção B. Item B3.1	✓			
8. Como podemos verificar se o modelo de <i>score</i> de crédito é eficaz em prever o risco em novos dados?	LGPD. Art. 7º/ OP. Seção G. Item G1.1		✓		
9. Quais métricas de desempenho devemos usar para avaliar a precisão e a robustez do <i>score</i> de crédito?	LGPD. Art. 9º / OP. Seção G. Item G1.1		✓		
10. Quais são os sistemas ou processos que utilizam o <i>score</i> de crédito para tomar decisões?	LGPD. Art. 49 / OP. Seção G. Item G1.1	✓			

Quadro 5 — Validação do modelo PLTR de acordo com o *framework*

(conclusão)

PRÁTICAS PARA MONTAGEM DO SCORE DE CRÉDITO	NORMA/LEI REFERÊNCIA	TC	PC	NC	N/A
11. Com que frequência devemos atualizar o modelo de <i>score</i> de crédito para garantir sua relevância contínua?	LGPD. Art. 46 / OP. Seção B. Item B4.1		✓		
12. Como podemos garantir que o <i>score</i> de crédito seja transparente e compreensível para os usuários?	LGPD. Art. 7º / OP. Seção B. Item B6.1		✓		
13. Quais medidas estamos tomando para proteger os dados pessoais dos indivíduos durante o processo?	LGPD. Art. 46 / OP. Seção A. Item A2.1	✓			
14. Como estamos garantindo que o <i>score</i> de crédito não esteja discriminando injustamente certos grupos de pessoas?	LGPD. Art. 7º / OP. Seção B. Item B3.1		✓		
15. Os clientes têm a oportunidade de contestar ou corrigir informações em seus <i>scores</i> de crédito?	LGPD. Art. 9º / OP. Seção B. Item B1.3	✓			

Fonte: elaboração própria (2023).

Com análise segundo o quadro com a validação do modelo PLTR, percebe-se que há alguns itens parcialmente atendidos, podendo ser melhorados. Seguem eles:

1. Quais são os objetivos específicos do *score* de crédito que estamos tentando alcançar? O item foi avaliado como PC (Parcialmente Compatível), pois os objetivos podem estar definidos de maneira geral, mas faltam detalhes ou metas mensuráveis específicas, o que é necessário para cumprir completamente os requisitos de transparência e especificidade da LGPD.

4. Como podemos garantir que os dados coletados estejam padronizados e prontos para análise? O item foi avaliado como PC (Parcialmente Compatível), pois os dados podem estar sendo coletados de forma padronizada, mas pode faltar uma documentação detalhada dos procedimentos ou uma auditoria regular para garantir a consistência e a prontidão para análise.

5. Qual algoritmo de modelagem é mais adequado para criar o *score* de crédito desejado? O item foi avaliado como PC (Parcialmente Compatível), portanto, pode haver uma escolha inicial de algoritmos, mas a avaliação contínua da adequação do algoritmo pode estar incompleta ou falta documentação sobre como a escolha do algoritmo atende aos critérios específicos estabelecidos pela LGPD.

6. Como devemos dividir os dados para treinar e testar o modelo de *score* de crédito? O item foi avaliado como PC (Parcialmente Compatível), pois a divisão dos dados pode estar sendo realizada, mas faltam detalhes ou práticas robustas para garantir a representatividade e evitar vieses nos conjuntos de treinamento e teste.

8. Como podemos verificar se o modelo de *score* de crédito é eficaz em prever o risco em novos dados? O item foi avaliado como PC (Parcialmente Compatível), pois pode haver métodos de verificação implementados, mas a eficácia em prever o risco pode não estar totalmente validada em diferentes cenários ou condições de mercado, faltando uma avaliação contínua e ajustes conforme necessário.

9. Quais métricas de desempenho devemos usar para avaliar a precisão e a robustez do *score* de crédito? O item foi avaliado como PC (Parcialmente Compatível), pois algumas métricas podem estar sendo usadas, mas pode haver uma falta de abrangência ou atualização das métricas para garantir que todas as dimensões de desempenho sejam cobertas adequadamente.

11. Com que frequência devemos atualizar o modelo de *score* de crédito para garantir sua relevância contínua? O item foi avaliado como PC (Parcialmente Compatível), pois há uma frequência de atualização estabelecida, mas pode não ser suficiente para garantir a relevância contínua devido a mudanças rápidas no mercado ou nas condições econômicas. Pode faltar um processo de revisão contínua para acompanhar essas mudanças.

12. Como podemos garantir que o *score* de crédito seja transparente e compreensível para os usuários? O item foi avaliado como PC (Parcialmente Compatível), pois pode haver alguma transparência, mas não em um nível que permita aos usuários entenderem completamente como o *score* é calculado e quais dados são utilizados. Faltam comunicações claras e acessíveis aos usuários sobre o processo.

14. Como estamos garantindo que o *score* de crédito não esteja discriminando injustamente certos grupos de pessoas? O item foi avaliado como PC (Parcialmente Compatível), pois podem existir medidas para evitar discriminação, mas faltam

verificações e auditorias regulares para garantir que essas medidas estejam funcionando conforme o esperado e que não haja discriminação implícita nos dados ou no modelo.

A próxima análise, Quadro 6, a ser feita será com o modelo Z-Score, uma ferramenta estatística usada para prever a probabilidade de falência de empresas. Ele combina cinco índices financeiros que refletem a liquidez, lucratividade, alavancagem, solvência e atividade da empresa. Inicialmente projetado para empresas públicas, pode ser adaptado para uso em empresas privadas. O Z-Score ajuda investidores, credores e gestores a avaliar riscos financeiros e a antecipar problemas financeiros. No entanto, possui limitações, como a necessidade de dados precisos e a sensibilidade a mudanças no ambiente econômico.

Quadro 6 — Validação do modelo Z-Score de acordo com o *framework*

<b>PRÁTICAS PARA MONTAGEM DO SCORE DE CRÉDITO</b>	<b>NORMA/LEI REFERÊNCIA</b>	<b>TC</b>	<b>PC</b>	<b>NC</b>	<b>N/A</b>
1. Quais são os objetivos específicos do <i>score</i> de crédito que estamos tentando alcançar?	LGPD. Art. 7º/OP. Seção A. Item A1.3		✓		
2. Quais são as variáveis-chave que devem ser consideradas na avaliação do risco de crédito?	LGPD. Art. 9º/OP. Seção B. Item B2.1		✓		
3. Onde podemos obter dados históricos relevantes sobre o comportamento de crédito dos indivíduos?	LGPD. Art. 49/OP. Seção A. Item A1.3			✓	
4. Como podemos garantir que os dados coletados estejam padronizados e prontos para análise?	LGPD. Art. 46 /OP. Seção A. Item A2.1	✓			
5. Qual algoritmo de modelagem é mais adequado para criar o <i>score</i> de crédito desejado?	LGPD. Art. 49 /OP. Seção A. Item A3.1	✓			

Quadro 6 — Validação do modelo Z-Score de acordo com o *framework*

(continuação)

PRÁTICAS PARA MONTAGEM DO SCORE DE CRÉDITO	NORMA/LEI REFERÊNCIA	TC	PC	NC	N/A
6. Como devemos dividir os dados para treinar e testar o modelo de <i>score</i> de crédito?	LGPD. Art. 49 / OP. Seção A. Item A3.1			✓	
7. Quais ajustes precisam ser feitos no modelo para garantir que ele se ajuste bem aos dados de treinamento?	LGPD. Art. 10º / OP. Seção B. Item B3.1		✓		
8. Como podemos verificar se o modelo de <i>score</i> de crédito é eficaz em prever o risco em novos dados?	LGPD. Art. 7º/ OP. Seção G. Item G1.1	✓			
9. Quais métricas de desempenho devemos usar para avaliar a precisão e a robustez do <i>score</i> de crédito?	LGPD. Art. 9º / OP. Seção G. Item G1.1	✓			
10. Quais são os sistemas ou processos que utilizarão o <i>score</i> de crédito para tomar decisões?	LGPD. Art. 49 / OP. Seção G. Item G1.1			✓	
11. Com que frequência devemos atualizar o modelo de <i>score</i> de crédito para garantir sua relevância contínua?	LGPD. Art. 46 / OP. Seção B. Item B4.1	✓			
12. Como podemos garantir que o <i>score</i> de crédito seja transparente e compreensível para os usuários?	LGPD. Art. 7º / OP. Seção B. Item B6.1			✓	
13. Quais medidas estamos tomando para proteger os dados pessoais dos indivíduos durante o processo?	LGPD. Art. 46 / OP. Seção A. Item A2.1			✓	
14. Como estamos garantindo que o <i>score</i> de crédito não esteja discriminando injustamente certos grupos de pessoas?	LGPD. Art. 7º / OP. Seção B. Item B3.1			✓	

Quadro 6 — Validação do modelo Z-Score de acordo com o *framework* (conclusão)

PRÁTICAS PARA MONTAGEM DO SCORE DE CRÉDITO	NORMA/LEI REFERÊNCIA	TC	PC	NC	N/A
15. Os clientes têm a oportunidade de contestar ou corrigir informações em seus <i>scores</i> de crédito?	LGPD. Art. 9º / OP. Seção B. Item B1.3			✓	

Fonte: elaboração própria (2023).

Com análise segundo o quadro de validação do modelo Z-Score, percebe-se que há alguns itens parcialmente atendidos e outros não compatíveis, podendo eles serem melhorados, como:

1. Quais são os objetivos específicos do *score* de crédito que estamos tentando alcançar? O item foi avaliado como PC (Parcialmente Compatível), pois os objetivos podem ser definidos de maneira geral, mas faltam detalhes específicos ou metas mensuráveis que garantam total transparência e cumprimento dos requisitos da LGPD.

2. Quais são as variáveis-chave que devem ser consideradas na avaliação do risco de crédito? O item foi avaliado como PC (Parcialmente Compatível), pois algumas variáveis-chave podem ser identificadas, mas pode haver falta de documentação detalhada ou de consideração completa de todas as variáveis relevantes conforme exigido pela LGPD.

3. Onde podemos obter dados históricos relevantes sobre o comportamento de crédito dos indivíduos? O item foi avaliado como NC (Não Compatível), pois a coleta de dados históricos relevantes sobre o comportamento de crédito pode não estar conforme os requisitos da LGPD, especialmente no que diz respeito ao consentimento e à proteção de dados pessoais. Pode haver falta de clareza sobre a origem dos dados, a legalidade de sua coleta e armazenamento e a segurança com que são mantidos.

6. Como devemos dividir os dados para treinar e testar o modelo de *score* de crédito? O item foi avaliado como NC (Não Compatível), pois a divisão dos dados para treinamento e teste pode não estar sendo feita de forma a evitar vieses e garantir representatividade. Isso pode resultar em um modelo que não seja preciso ou justo,

comprometendo a confiabilidade das previsões de crédito e a conformidade com a LGPD, a qual exige práticas transparentes e justas.

7. Quais ajustes precisam ser feitos no modelo para garantir que ele se ajuste bem aos dados de treinamento? O item foi avaliado como PC (Parcialmente Compatível), pois algumas métricas podem estar sendo usadas, mas pode haver falta de abrangência ou atualização das métricas para garantir que todas as dimensões de desempenho sejam cobertas adequadamente. Algumas métricas podem estar sendo usadas, mas pode haver falta de abrangência ou atualização das métricas para garantir que todas as dimensões de desempenho sejam cobertas adequadamente.

10. Quais são os sistemas ou processos que utilizarão o *score* de crédito para tomar decisões? O item foi avaliado como NC (Não Compatível), pois pode haver falta de documentação ou clareza sobre quais sistemas ou processos utilizam o *score* de crédito, como eles são implementados e como as decisões são tomadas. A LGPD exige transparência e clareza sobre o uso de dados pessoais, e a ausência dessas informações pode comprometer a conformidade.

12. Como podemos garantir que o *score* de crédito seja transparente e compreensível para os usuários? O item foi avaliado como NC (Não Compatível), pois a falta de transparência e de explicações compreensíveis sobre como o *score* de crédito é calculado pode resultar em não conformidade com a LGPD. Os usuários devem entender claramente os critérios e dados usados para calcular seus *scores*, e a falta dessa transparência compromete a conformidade.

13. Quais medidas estamos tomando para proteger os dados pessoais dos indivíduos durante o processo? O item foi avaliado como NC (Não Compatível), pois a proteção de dados pessoais pode não estar sendo adequadamente abordada. A LGPD exige que medidas rigorosas de segurança sejam implementadas para proteger dados pessoais, e a ausência dessas medidas ou a falta de evidências de sua eficácia pode resultar em não conformidade. A proteção de dados pessoais pode não estar sendo adequadamente abordada.

14. Como estamos garantindo que o *score* de crédito não esteja discriminando injustamente certos grupos de pessoas? O item foi avaliado como NC (Não Compatível), pois a falta de medidas eficazes para garantir que o *score* de crédito não discrimine injustamente certos grupos pode resultar em não conformidade com a

LGPD. É essencial implementar e revisar regularmente práticas que evitem discriminação, e a ausência dessas práticas compromete a conformidade.

15. Os clientes têm a oportunidade de contestar ou corrigir informações em seus *scores* de crédito? O item foi avaliado como NC (Não Compatível), pois a ausência de um processo claro e acessível para que os clientes contestem ou corrijam informações em seus *scores* de crédito pode resultar em não conformidade com a LGPD, a qual exige que os indivíduos tenham o direito de acessar, corrigir e contestar os dados pessoais mantidos sobre eles.

A análise seguinte, demonstrada no Quadro 7, está sendo feita com o modelo de risco de conjunto homogêneo, o qual envolve a combinação de múltiplos modelos do mesmo tipo ou da mesma família de algoritmos para melhorar o desempenho geral. Essa técnica aproveita a diversidade dos modelos para aumentar a precisão das previsões e a capacidade de generalização. Funciona agrupando, por exemplo, várias árvores de decisão similares, em que cada modelo contribui com suas forças e compensa suas fraquezas. Ao integrar suas previsões, reduz-se a probabilidade de erros, resultando em classificações mais precisas. Técnicas comuns de conjuntos homogêneos incluem o *bagging* e o uso de Florestas Aleatórias, sendo amplamente aplicadas em tarefas de classificação, regressão e detecção de anomalias.

Quadro 7 — Validação do conjunto homogêneo de acordo com o *framework*

PRÁTICAS PARA MONTAGEM DO SCORE DE CRÉDITO	NORMA/LEI REFERÊNCIA	TC	PC	NC	N/A
1. Quais são os objetivos específicos do <i>score</i> de crédito que estamos tentando alcançar?	LGPD. Art. 7º/OP. Seção A. Item A1.3	✓			
2. Quais são as variáveis-chave que devem ser consideradas na avaliação do risco de crédito?	LGPD. Art. 9º/OP. Seção B. Item B2.1	✓			



Quadro 7 — Validação do conjunto homogêneo de acordo com o *framework*  
(continuação)

PRÁTICAS PARA MONTAGEM DO SCORE DE CRÉDITO	NORMA/LEI REFERÊNCIA	TC	PC	NC	N/A
3. Onde podemos obter dados históricos relevantes sobre o comportamento de crédito dos indivíduos?	LGPD. Art. 49/ OP. Seção A. Item A1.3		✓		
4. Como podemos garantir que os dados coletados estejam padronizados e prontos para análise?	LGPD. Art. 46 / OP. Seção A. Item A2.1	✓			
5. Qual algoritmo de modelagem é mais adequado para criar o <i>score</i> de crédito desejado?	LGPD. Art. 49 / OP. Seção A. Item A3.1	✓			
6. Como devemos dividir os dados para treinar e testar o modelo de <i>score</i> de crédito?	LGPD. Art. 49 / OP. Seção A. Item A3.1	✓			
7. Quais ajustes precisam ser feitos no modelo para garantir que ele se ajuste bem aos dados de treinamento?	LGPD. Art. 10º / OP. Seção B. Item B3.1	✓			
8. Como podemos verificar se o modelo de <i>score</i> de crédito é eficaz em prever o risco em novos dados?	LGPD. Art. 7º/ OP. Seção G. Item G1.1	✓			
9. Quais métricas de desempenho devemos usar para avaliar a precisão e a robustez do <i>score</i> de crédito?	LGPD. Art. 9º / OP. Seção G. Item G1.1	✓			
10. Quais são os sistemas ou processos que utilizarão o <i>score</i> de crédito para tomar decisões?	LGPD. Art. 49 / OP. Seção G. Item G1.1		✓		
11. Com que frequência devemos atualizar o modelo de <i>score</i> de crédito para garantir sua relevância contínua?	LGPD. Art. 46 / OP. Seção B. Item B4.1	✓			

Quadro 7 — Validação do conjunto homogêneo de acordo com o *framework* (conclusão)

PRÁTICAS PARA MONTAGEM DO SCORE DE CRÉDITO	NORMA/LEI REFERÊNCIA	TC	PC	NC	N/A
12. Como podemos garantir que o <i>score</i> de crédito seja transparente e compreensível para os usuários?	LGPD. Art. 7º / OP. Seção B. Item B6.1		✓		
13. Quais medidas estamos tomando para proteger os dados pessoais dos indivíduos durante o processo?	LGPD. Art. 46 / OP. Seção A. Item A2.1		✓		
14. Como estamos garantindo que o <i>score</i> de crédito não esteja discriminando injustamente certos grupos de pessoas?	LGPD. Art. 7º / OP. Seção B. Item B3.1		✓		
15. Os clientes têm a oportunidade de contestar ou corrigir informações em seus <i>scores</i> de crédito?	LGPD. Art. 9º / OP. Seção B. Item B1.3		✓		

Fonte: elaboração própria (2023).

Com análise segundo o quadro de validação de conjunto homogêneo, percebe-se que temos alguns itens parcialmente atendidos, podendo eles serem melhorados, como:

3. Onde podemos obter dados históricos relevantes sobre o comportamento de crédito dos indivíduos? O item foi avaliado como PC (Parcialmente Compatível), pois a combinação de múltiplos modelos pode estar sendo usada para integrar dados de várias fontes, mas ainda há inconsistências na padronização e integração desses dados históricos. Melhorar a padronização e integração dos dados pode aumentar a precisão e a confiabilidade das previsões.

10. Quais são os sistemas ou processos que utilizarão o *score* de crédito para tomar decisões? O item foi avaliado como PC (Parcialmente Compatível), pois existe uma implementação inicial de modelos combinados para suportar decisões de crédito, mas a documentação e integração completa desses sistemas e processos ainda não estão finalizadas. É necessário integrar completamente todos os sistemas e processos relevantes.

12. Como podemos garantir que o *score* de crédito seja transparente e compreensível para os usuários? O item foi avaliado como PC (Parcialmente Compatível), pois há um esforço inicial para combinar modelos que expliquem o *score* de crédito, mas a comunicação dessas explicações aos usuários ainda não é clara e compreensível o suficiente. Melhorar a transparência e a clareza das explicações é essencial.

13. Quais medidas estamos tomando para proteger os dados pessoais dos indivíduos durante o processo? O item foi avaliado como PC (Parcialmente Compatível), pois as medidas de segurança estão sendo implementadas de forma diversificada, mas existem lacunas na implementação completa e na documentação dessas práticas de proteção de dados. É necessário fortalecer as medidas de proteção e garantir uma implementação completa.

14. Como estamos garantindo que o *score* de crédito não esteja discriminando injustamente certos grupos de pessoas? O item foi avaliado como PC (Parcialmente Compatível), pois há uma tentativa inicial de combinar modelos que evitem a discriminação, mas a eficácia dessas medidas ainda não foi totalmente validada. É importante implementar e validar rigorosamente práticas que garantam a não discriminação.

15. Os clientes têm a oportunidade de contestar ou corrigir informações em seus *scores* de crédito? O item foi avaliado como PC (Parcialmente Compatível), pois existe um processo inicial para combinar diferentes fontes de feedback dos clientes, mas o processo de contestação e correção de informações ainda não está completamente estabelecido e acessível. Estabelecer um processo claro e acessível é fundamental.

Por fim, a última análise feita, Quadro 8, é com o modelo de conjunto heterogêneo que combina diferentes tipos de modelos e algoritmos de diversas famílias para melhorar o desempenho global na resolução de problemas. Essa abordagem capitaliza na diversidade dos modelos para minimizar as limitações de um por meio das forças de outro, oferecendo previsões mais precisas e robustas, especialmente em cenários complexos. Técnicas comuns usadas incluem Stacking, na qual as previsões de vários modelos são integradas por um modelo de nível superior; e o sistema de "voto ponderado", que determina a previsão final com base

na contribuição de cada modelo. A seleção cuidadosa e o ajuste dos modelos base são essenciais para maximizar a eficácia do conjunto heterogêneo.

Quadro 8 — Validação do conjunto heterogêneo de acordo com o *framework*

PRÁTICAS PARA MONTAGEM DO SCORE DE CRÉDITO	NORMA/LEI REFERÊNCIA	TC	PC	NC	N/A
1. Quais são os objetivos específicos do <i>score</i> de crédito que estamos tentando alcançar?	LGPD. Art. 7º/OP. Seção A. Item A1.3	✓			
2. Quais são as variáveis-chave que devem ser consideradas na avaliação do risco de crédito?	LGPD. Art. 9º/OP. Seção B. Item B2.1	✓			
3. Onde podemos obter dados históricos relevantes sobre o comportamento de crédito dos indivíduos?	LGPD. Art. 49/OP. Seção A. Item A1.3		✓		
4. Como podemos garantir que os dados coletados estejam padronizados e prontos para análise?	LGPD. Art. 46 /OP. Seção A. Item A2.1	✓			
5. Qual algoritmo de modelagem é mais adequado para criar o <i>score</i> de crédito desejado?	LGPD. Art. 49 /OP. Seção A. Item A3.1	✓			
6. Como devemos dividir os dados para treinar e testar o modelo de <i>score</i> de crédito?	LGPD. Art. 49 /OP. Seção A. Item A3.1	✓			
7. Quais ajustes precisam ser feitos no modelo para garantir que ele se ajuste bem aos dados de treinamento?	LGPD. Art. 10º /OP. Seção B. Item B3.1	✓			
8. Como podemos verificar se o modelo de <i>score</i> de crédito é eficaz em prever o risco em novos dados?	LGPD. Art. 7º/OP. Seção G. Item G1.1	✓			

Quadro 8 — Validação do conjunto heterogêneo de acordo com o *framework* (conclusão)

PRÁTICAS PARA MONTAGEM DO SCORE DE CRÉDITO	NORMA/LEI REFERÊNCIA	TC	PC	NC	N/A
9. Quais métricas de desempenho devemos usar para avaliar a precisão e a robustez do <i>score</i> de crédito?	LGPD. Art. 9º / OP. Seção G. Item G1.1	✓			
10. Quais são os sistemas ou processos que utilizarão o <i>score</i> de crédito para tomar decisões?	LGPD. Art. 49 / OP. Seção G. Item G1.1	✓			
11. Com que frequência devemos atualizar o modelo de <i>score</i> de crédito para garantir sua relevância contínua?	LGPD. Art. 46 / OP. Seção B. Item B4.1	✓			
12. Como podemos garantir que o <i>score</i> de crédito seja transparente e compreensível para os usuários?	LGPD. Art. 7º / OP. Seção B. Item B6.1		✓		
13. Quais medidas estamos tomando para proteger os dados pessoais dos indivíduos durante o processo?	LGPD. Art. 46 / OP. Seção A. Item A2.1		✓		
14. Como estamos garantindo que o <i>score</i> de crédito não esteja discriminando injustamente certos grupos de pessoas?	LGPD. Art. 7º / OP. Seção B. Item B3.1	✓			
15. Os clientes têm a oportunidade de contestar ou corrigir informações em seus <i>scores</i> de crédito?	LGPD. Art. 9º / OP. Seção B. Item B1.3	✓			

Fonte: elaboração própria (2023).

Com análise do segundo o quadro com a validação de conjunto heterogêneo, percebe-se que alguns itens parcialmente atendidos, podendo ser melhorados, como:

3. Onde podemos obter dados históricos relevantes sobre o comportamento de crédito dos indivíduos? O item foi avaliado como PC (Parcialmente Compatível), pois a combinação de diferentes modelos pode estar sendo utilizada para integrar dados

históricos de diversas fontes, mas pode haver inconsistências na padronização e na integração desses dados. A abordagem heterogênea ajuda a combinar informações diversas, mas a falta de uniformidade completa na coleta e processamento de dados pode resultar em compatibilidade parcial.

12. Como podemos garantir que o *score* de crédito seja transparente e compreensível para os usuários? O item foi avaliado como PC (Parcialmente Compatível), pois o uso de diferentes modelos para explicar o *score* de crédito pode aumentar a transparência e a compreensibilidade, mas a integração dessas explicações pode não ser completamente clara para os usuários. A combinação de diversos modelos pode resultar em uma comunicação complexa e, portanto, menos transparente.

13. Quais medidas estamos tomando para proteger os dados pessoais dos indivíduos durante o processo? O item foi avaliado como PC (Parcialmente Compatível), pois a utilização de diversos modelos para identificar e proteger dados pessoais pode oferecer uma abordagem mais robusta, mas a implementação dessas medidas de segurança pode não ser totalmente consistente e documentada. A diversidade de modelos pode criar lacunas na proteção de dados se não for bem coordenada.

Com tudo isso posto, pode-se concluir que a integração de *frameworks* baseados em *Open Finance* e LGPD com modelos específicos de *score* de crédito oferece uma abordagem robusta e transparente para a avaliação de risco. Os modelos de *score* de crédito, como PLTR e Z-Score, bem como os modelos de conjunto homogêneo e heterogêneo, proporcionam diferentes perspectivas e métodos para análise de crédito, cada um com suas características distintas. O modelo PLTR e o modelo Z-Score diferem fundamentalmente na maneira como tratam as informações e na natureza dos dados que analisam.

O PLTR é uma fusão entre regressão logística e árvores de decisão, ideal para capturar relações complexas e não lineares nos dados. Esse modelo é particularmente útil quando é necessário manter a interpretabilidade das decisões, uma vez que ele gera regras claras de decisão a partir das árvores de decisão. Em contraste, o Z-Score foca na solvência financeira e usa uma combinação de indicadores financeiros para determinar a probabilidade de falência de uma empresa.

Esse modelo é mais direto e se baseia em fórmulas matemáticas estabelecidas para fornecer um *score* rápido e facilmente comparável entre diferentes empresas.

Entre os modelos de conjunto, o homogêneo e o heterogêneo também se diferenciam significativamente em suas abordagens. O modelo de conjunto homogêneo utiliza múltiplos algoritmos do mesmo tipo para criar uma previsão mais estável e reduzir a variância, o que é ideal para casos em que a consistência e a redução de erros são prioritárias. Por outro lado, o modelo de conjunto heterogêneo combina diferentes tipos de algoritmos para explorar suas vantagens individuais e compensar suas fraquezas. Essa abordagem é benéfica em situações complexas, onde diferentes perspectivas e técnicas são necessárias para capturar todas as nuances dos dados de crédito.

Portanto, a escolha entre esses modelos deve ser guiada pelo contexto específico da análise de crédito, pelas necessidades de interpretação dos resultados e pela complexidade dos dados envolvidos. Cada modelo oferece vantagens únicas que podem ser mais bem aproveitadas em situações específicas para maximizar a eficácia e a precisão das avaliações de crédito.

## 6. CONSIDERAÇÕES FINAIS

A análise e avaliação de risco de crédito no Brasil requer uma abordagem complexa que considere a segurança e conformidade com regulamentações como a LGPD. Este estudo destaca a importância dos *scores* de crédito na mitigação de riscos financeiros e integração com práticas de proteção de dados pessoais, devido ao aumento significativo de fraudes financeiras global.

No Brasil, a diversidade socioeconômica e a complexidade das transações financeiras intensificam a relevância dessas questões, com as instituições brasileiras investindo massivamente em segurança. A categorização de clientes pelas instituições financeiras, baseada em dados internos e políticas corporativas, enfrenta desafios devido à necessidade de conformidade com LGPD.

Desse modo, o *framework* proposto avalia essa conformidade na criação de *scores* de crédito, ferramenta essencial para avaliar riscos financeiros com base no histórico de pagamentos e comportamento financeiro. Diversos modelos de avaliação de crédito, como Z-Score, PLTR e modelos de risco de conjunto homogêneo e heterogêneo, são explorados. O Z-Score prevê a solvência de empresas, enquanto o PLTR combina árvores de decisão e regressão logística para uma avaliação mais precisa do risco de crédito.

Os riscos financeiros são classificados em crédito, mercado e operacionais, sendo a análise e mitigação desses riscos essenciais para a estabilidade financeira. A LGPD e o RGPD visam proteger dados pessoais, impondo obrigações significativas às organizações, como consentimento claro para coleta e uso de dados, minimização de dados e transparência.

A conformidade com essas regulamentações é crucial no desenvolvimento e aplicação de *scores* de crédito, trazendo benefícios como redução de fraudes e maior confiança dos consumidores, apesar dos desafios na adaptação de sistemas e práticas.

As metodologias avançadas para criação de *scores* de crédito incluem técnicas de aprendizado de máquina e análise estatística, como o modelo PLTR, que melhora a capacidade preditiva na concessão de crédito ao combinar adaptabilidade das árvores de decisão com a clareza da regressão logística. A conformidade, dos modelos propostos, com os princípios de proteção de dados da LGPD e RGPD é



fundamental, incluindo coleta restrita de dados, segurança e transparência no uso dos dados.

A implementação dessas regulamentações e o uso de modelos avançados de *score* de crédito oferecem inúmeros benefícios, como redução de fraudes e melhoria da confiança no sistema financeiro, mas também apresentam desafios como a adaptação de sistemas e a necessidade de treinamento dos colaboradores. As instituições financeiras devem investir em soluções de TI e segurança da informação para atender às exigências legais e fortalecer a segurança no setor financeiro.

Este estudo aborda a atual necessidade de um guia universal para a construção de *scores* de crédito pelas instituições financeiras, visando promover a interoperabilidade e a transparência no sistema financeiro, destacando a importância da Open Finance para resolver disparidades nos métodos de cálculo e tornar o processo de avaliação de crédito mais transparente e previsível.

Com base nos estudos de vários artigos citados ao longo do trabalho, e após passar por cada um dos passos e entender o que é o *score* de crédito e os seus modelos; foi sugerido um método sobre como trabalhar o *score* por meio da Open Finance; demonstrando como é possível aperfeiçoá-lo de acordo com a LGPD, porquanto o *framework* proposto busca garantir que os modelos de *score* de crédito sejam mais transparentes e seguros.

O *framework* propõe práticas para garantir que os modelos não utilizem dados discriminatórios, evitando qualquer violação da LGPD e assegurando um tratamento justo e ético dos dados pessoais. Sua estrutura não só eleva a confiança dos consumidores em serviços financeiros, mas também ajuda as instituições a se manterem competitivas e em conformidade com as normas. A interação entre reguladores, instituições financeiras e especialistas em tecnologia é essencial para o sucesso e a sustentabilidade dessas práticas.

Realizou-se a validação do *framework* proposto, apontando que os modelos de *score* de crédito podem e devem ser melhorados, por exemplo, percebeu-se que o resultado da validação do modelo PLTR não há compatibilidade com alguns itens, conforme tratamento dos apontamentos feitos nas respectivas fragilidades, visando maior aderência e compatibilidade com a proposta apresentada, sendo necessário melhorar cada fase do modelo. No planejamento, deve-se definir metas específicas, realistas e alcançáveis, identificar todas as variáveis relevantes para o risco de crédito

e padronizar a coleta de dados. Na implementação, é crucial obter dados históricos de fontes confiáveis, selecionar algoritmos adequados, treinar modelos com validação cruzada e dividir dados corretamente. No teste, deve-se verificar a eficácia dos modelos usando métricas apropriadas, garantir transparência e proteger dados pessoais com medidas robustas de segurança. Na revisão, é importante atualizar regularmente os modelos, coletar feedback dos clientes para ajustes e garantir que os modelos não discriminem de forma injusta. Essas ações asseguram a conformidade com as melhores práticas e regulamentos, resultando em um sistema de *score* de crédito justo e eficaz.

O modelo Z-Score também não é 100% compatível com todas as práticas, segundo o *framework*, porém o modelo PLTR não tinha nenhum dos itens avaliados como Não Compatível. Já no modelo Z-Score há algumas práticas classificadas como sendo não compatíveis, ou seja, o modelo Z-Score necessita de mais melhorias, tais como: é necessário garantir dados históricos padronizados e de alta qualidade, documentando procedimentos de coleta e integrando diferentes fontes de maneira consistente. É crucial realizar uma análise completa para identificar todas as variáveis relevantes na avaliação do risco de crédito, documentando-as detalhadamente. A escolha dos algoritmos deve ser baseada em análises de desempenho, com treinamento usando dados diversificados e validações cruzadas para evitar o *overfitting*. A divisão de dados deve ser robusta, assegurando representatividade e evitando vieses. Além disso, é essencial realizar testes contínuos para verificar a eficácia dos modelos, utilizando métricas apropriadas como acurácia, precisão e *recall*, fornecendo documentação clara sobre os cálculos do *score*. É necessário, ainda, implementar medidas de segurança robustas, realizar testes de segurança regulares e auditorias é fundamental para proteger os dados pessoais. Garantir que o modelo não discrimine injustamente é uma prioridade, exigindo análises regulares e correções de vieses. Ademais, estabelecer um processo claro para que os clientes possam contestar ou corrigir informações nos scores de crédito, coletando feedback para melhorias contínuas, é vital. Por fim, revisões e atualizações regulares dos modelos devem ser estabelecidas, monitorando mudanças no mercado e ajustando conforme necessário. Tais ações garantirão que o modelo Z-Score se torne mais justo, transparente, seguro e eficaz.

Segundo o *framework*, o modelo de conjunto homogêneo, em comparação aos dois já citados acima, parece ser uma proposta mais robusta, devido somente a algumas práticas serem parcialmente compatíveis, mas ainda assim precisa de melhorias como os outros, tais quais: Otimizar a padronização e integração de dados, garantindo alta qualidade e consistência. Combinação de múltiplos modelos deve ser mais robusta para minimizar inconsistências e aumentar a precisão. Documentação dos sistemas e processos que utilizam o *score* de crédito precisa ser completa e detalhada. Transparência do *score* de crédito deve ser melhorada com explicações claras e acessíveis. As medidas de segurança dos dados pessoais precisam ser fortalecidas e documentadas. É essencial realizar análises regulares para evitar discriminação e estabelecer um processo claro para que os clientes contestem ou corrijam informações. Coletar *feedback* contínuo ajudará a melhorar os processos e modelos. É esperado um modelo de conjunto homogêneo mais robusto e seguro adotando esses apontamentos.

Por último, avaliou-se o modelo de conjunto heterogêneo. Em questão de eficiência, pode-se dizer que ele tem similaridade ao modelo de conjunto homogêneo, mas, como todos os outros já citados, precisa também de melhorias, pois nem todas as práticas de acordo com o *framework* são totalmente compatíveis, nas quais as melhorias são: garantir total compatibilidade com as boas práticas, é necessário padronizar e integrar dados de alta qualidade de forma consistente, otimizar a combinação de diversos modelos para maximizar precisão e robustez, e detalhar a documentação dos sistemas e processos. Além disso, é crucial melhorar a transparência e a clareza das explicações do *score* de crédito para os usuários, reforçar as medidas de segurança dos dados pessoais, garantindo a não discriminação injusta por parte dos modelos. Estabelecer um processo claro para que os clientes contestem ou corrijam informações e coletar *feedback* contínuo para melhorias constantes é essencial e ações como essas auxiliam numa maior garantia no uso do modelo.

Por fim, conclui-se que a implementação de modelos de *score* de crédito deve ser meticulosamente planejada para garantir conformidade com as legislações vigentes, como a LGPD, assegurando a proteção dos dados pessoais dos usuários.

As instituições financeiras devem adotar práticas rigorosas de conformidade para garantir que a coleta e o uso de dados estejam alinhados com as diretrizes

estabelecidas pelas regulamentações de proteção de dados. A transparência na coleta de dados e a obtenção de consentimento explícito dos usuários são cruciais para manter a confiança dos consumidores e evitar penalidades legais. A segurança dos dados pessoais deve ser uma prioridade. As instituições devem implementar medidas robustas de segurança, como criptografia e autenticação, a fim de proteger os dados contra acessos não autorizados e vazamentos. Além disso, é fundamental estabelecer processos regulares de atualização e verificação de dados para garantir a precisão e a atualidade das informações coletadas. Os principais desafios na implementação de modelos de *score* de crédito incluem a necessidade de adaptação constante às mudanças regulatórias e a mitigação de riscos associados à coleta e ao uso de dados pessoais. No entanto, essas práticas também apresentam oportunidades para aprimorar a precisão das avaliações de crédito e fortalecer a segurança das transações financeiras.

Em síntese, a implementação de modelos de *score* de crédito eficazes e seguros é uma tarefa complexa que exige atenção contínua à conformidade legal, à segurança dos dados e ao uso de tecnologias avançadas. As instituições financeiras devem estar preparadas para enfrentar os desafios e aproveitar as oportunidades apresentadas por essas práticas, garantindo uma avaliação de crédito justa, precisa e segura.

## **6.2. Proposta de trabalhos futuros**

Este trabalho demonstrou o potencial de aplicação de um *framework* otimizado para análise de *score* de crédito seguro. No entanto, diversos aspectos e frentes de trabalho ainda podem ser trabalhados visando um cenário global, como aprofundar a aplicabilidade da proposta com uso do RGPD e *American Data Privacy Protection Act* (ADPPA), proporcionando maior abrangência e extensibilidade de diferentes mercados do nacional, podendo ser utilizado por instituições financeiras tanto da Europa como dos Estados Unidos.

## REFERÊNCIAS

ALA'RAJ, Maher; ABBOD, Maysam F. Classifiers consensus system approach for credit scoring. **Knowledge-Based Systems**, v. 104, p. 89–105, 2016. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0950705116300569>. Acesso em: 10 jun. 2024.

ALTMAN, Edward I. Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy. **The Journal of Finance**, v. 23, n. 4, p. 589–609, 1968. DOI: 10.2307/2978933. Disponível em: <https://doi.org/10.2307/2978933>. Acesso em: 25 jun. 2024.

ALTMAN, Edward I.; HOTCHKISS, Edith. **Corporate financial distress and bankruptcy: predict and avoid bankruptcy, analyze and invest in distressed debt**. Hoboken, NJ: Wiley, 2006.

ALTMAN, Edward I.; SABATO, Gabriele; WILSON, Nick. The Value of Non-Financial Information in SME Risk Management. **SSRN Electronic Journal**, 2008. DOI: 10.2139/ssrn.1320612. Disponível em: [https://papers.ssrn.com/sol3/papers.cfm?abstract\\_id=1320612](https://papers.ssrn.com/sol3/papers.cfm?abstract_id=1320612). Acesso em: 20 jun. 2024.

ARAÚJO, Elaine Aparecida. Risco de Crédito: Desenvolvimento de modelo Credit Scoring para a gestão da inadimplência de uma instituição de microcrédito. *In*: IPEA, **Prêmio IPEA-Caixa 2006: monografias premiadas**. Brasília: IPEA, 2006, p. 319-350. Disponível em: [https://www.ipea.gov.br/ipeacaixa/premio2006/docs/trabpremiados/lpeaCaixa2006\\_Profissional\\_02lugar\\_tema03.pdf](https://www.ipea.gov.br/ipeacaixa/premio2006/docs/trabpremiados/lpeaCaixa2006_Profissional_02lugar_tema03.pdf). Acesso em: 18 jun. 2024.

ARYA, Shweta; ECKEL, Catherine; WICHMAN, Colin. Anatomy of the credit score. **Journal of Economic Behavior & Organization**, v. 95, p. 175–185, nov. 2013. DOI: 10.1016/j.jebo.2011.05.005. Disponível em: <https://doi.org/10.1016/j.jebo.2011.05.005>. Acesso em: 20 jun. 2024.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). **NBR 31000**: Gestão de riscos - Princípios e diretrizes. Rio de Janeiro, 2009. Disponível em: <https://gestravp.files.wordpress.com/2013/06/iso31000-gestc3a3o-de-riscos.pdf>. Acesso em: 10 jun. 2024.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). **NBR ISSO/IEC 31010**: Gestão de Riscos - Técnicas para o processo de avaliação de riscos. Rio de Janeiro, 2009. Disponível em: [https://planejamentoestrategico.mcti.gov.br/arquivos/Gestao\\_Riscos\\_Tecnicas\\_%20ABNT%20NBR%20ISO-IEC%2031010-2012.pdf](https://planejamentoestrategico.mcti.gov.br/arquivos/Gestao_Riscos_Tecnicas_%20ABNT%20NBR%20ISO-IEC%2031010-2012.pdf). Acesso em: 10 jun. 2024.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). **NBR ISO 31.000**: Gestão de Riscos - Princípios e Diretrizes. Rio de Janeiro, 2009. Disponível em: <https://dintegcgin.saude.gov.br/attachments/download/23/2018%20->

%20Diretrizes%20-%20Gest%C3%A3o%20de%20Riscos\_ABNT%20NBR%20ISO%2031000.pdf. Acesso em: 10 jun. 2024.

BANCO CENTRAL DO BRASIL (Bacen). Open Finance. **Banco Central do Brasil**, [s. l., s. d.]. Disponível em: <https://www.bcb.gov.br/estabilidadefinanceira/openfinance>. Acesso em: 10 jun. 2024.

BASEL COMMITTEE ON BANKING SUPERVISION (BIS). **Basel III: A global regulatory framework for more resilient banks and banking systems**. Basel, Suíça: Bank for International Settlements Communications, dez. 2010. Disponível em: <https://www.bis.org/publ/bcbs189.pdf>. Acesso em: 20 jun. 2024.

BEAVER, William H. Behavioral aspects of financial predictions. **Journal of Accounting Research**, v. 6, n. 2, p. 199–222, 1968.

BENOIT, Sylvain; HURLIN, Christophe; PÉRIGNON, Christophe. Pitfalls in systemic-risk scoring. **Journal of Financial Intermediation**, v. 38, p. 19–44, abr. 2019. DOI: 10.1016/j.jfi.2018.05.004. Disponível em: <https://doi.org/10.1016/j.jfi.2018.05.004>. Acesso em: 10 jun. 2024.

BERTO, Rosa Maria Villares S.; NAKANO, Davi Noboru. A produção científica nos anais do encontro nacional de engenharia de produção: um levantamento de métodos e tipos de pesquisa. **Prod.**, São Paulo, v. 9, n. 2, 1999, p. 65-75. DOI: 10.1590/S0103-65131999000200005. Disponível em: <https://doi.org/10.1590/S0103-65131999000200005>. Acesso em: 10 jun. 2024.

BRASIL. Lei n.º 8.078, de 11 de setembro de 1990. Dispõe sobre a proteção do consumidor e dá outras providências. **Diário Oficial da União**: seção 1 (suplemento), Brasília, DF, p. 1, 12 set. 1990. Disponível em: <https://www2.camara.leg.br/legin/fed/lei/1990/lei-8078-11-setembro-1990-365086-publicacaooriginal-1-pl.html>. Acesso em: 10 jun. 2024.

BRASIL. Lei n.º 12.414, de setembro de 2011. Disciplina a formação e consulta a bancos de dados com informações de adimplemento, de pessoas naturais ou de pessoas jurídicas, para formação de histórico de crédito. **Diário Oficial da União**: seção 1, Brasília, DF, p. 2, col. 2, 10 jun. 2011. Disponível em: <https://legis.senado.leg.br/norma/585411/publicacao/15759253>. Acesso em: 10 jun. 2024.

BRASIL. Banco Central do Brasil (Bacen). Resolução n.º 4.557, de 23 de fevereiro de 2017. Dispões sobre a estrutura de gerenciamento de riscos e a estrutura de gerenciamento de capital. **Diário Oficial da União**: seção 1, Brasília, DF, ano 154, n. 61, p. 41-46, 1 mar. 2017. Disponível em: [https://normativos.bcb.gov.br/Lists/Normativos/Attachments/50344/Res\\_4557\\_v1\\_O.pdf](https://normativos.bcb.gov.br/Lists/Normativos/Attachments/50344/Res_4557_v1_O.pdf). Acesso em: 10 jun. 2024.

BRASIL. Banco Central do Brasil (Bacen). Resolução Conjunta n.º 1, de 4 de maio de 2020. Dispõe sobre a implementação do Open Finance (Redação dada, a partir

de 2/5/2022, pela Resolução Conjunta n.º 4, de 24/3/2022). **Diário Oficial da União**: seção 1, Brasília, DF, ano 158, n. 84, p. 34-38, 5 maio 2020. Disponível em: [https://normativos.bcb.gov.br/Lists/Normativos/Attachments/51028/Res\\_Conj\\_0001\\_v5\\_P.pdf](https://normativos.bcb.gov.br/Lists/Normativos/Attachments/51028/Res_Conj_0001_v5_P.pdf). Acesso em: 10 jun. 2024.

BRASIL. Banco Central do Brasil (Bacen). Resolução CMN n.º 3.919, de 25 de novembro de 2010. Altera e consolida as normas sobre cobrança de tarifas pela prestação de serviços por parte das instituições financeiras e demais instituições autorizadas a funcionar pelo Banco Central do Brasil e dá outras providências. **Sisbacen**: Brasília, DF, 25 nov. 2010. Disponível em: [https://normativos.bcb.gov.br/Lists/Normativos/Attachments/49514/Res\\_3919\\_v7\\_P.pdf](https://normativos.bcb.gov.br/Lists/Normativos/Attachments/49514/Res_3919_v7_P.pdf). Acesso em: 10 jun. 2024.

BRASIL. Banco Central do Brasil (Bacen). Resolução Conjunta n.º 4, de 24 de março de 2022. Altera a Resolução Conjunta n.º 1, de 4 de maio de 2020, para dispor sobre o Open Finance. **Diário Oficial da União**: seção 1, Brasília, DF, 28 mar. 2022. Disponível em: <https://www.bcb.gov.br/estabilidadefinanceira/exibenormativo?tipo=Resolu%C3%A7%C3%A3o%20Conjunta&numero=4>. Acesso em: 10 jun. 2024

BRASIL. Superior Tribunal de Justiça. Súmula n.º 550. A utilização de escore de crédito, método estatístico de avaliação de risco que não constitui banco de dados, dispensa o consentimento do consumidor, que terá o direito de solicitar esclarecimentos sobre as informações pessoais valoradas e as fontes dos dados considerados no respectivo cálculo. **Diário da Justiça Eletrônico**: Brasília, DF, 14 out. 2015. Disponível em: [https://www.stj.jus.br/docs\\_internet/jurisprudencia/tematica/download/SU/Sumulas/SumuladasSTJ.pdf#page=2012&zoom=100,48,69](https://www.stj.jus.br/docs_internet/jurisprudencia/tematica/download/SU/Sumulas/SumuladasSTJ.pdf#page=2012&zoom=100,48,69). Acesso em: 10 jun. 2024.

DIAS, Filipe do Nascimento. **Open Finance no Setor Bancário Brasileiro, Entre 2021 e 2023**: Oportunidades e Desafios. 2024. Monografia (Bacharel em Ciências Econômicas – Pontifícia Universidade Católica de Goiás, Goiânia, 2024. Disponível em: <https://repositorio.pucgoias.edu.br/jspui/handle/123456789/7572>. Acesso em: xx jun. 2024.

DIAS, Ricardo; MURAKOSHI, Vivian Y. Fatores comuns de risco de mercado, tamanho, valor e diferenciais de juros nos retornos esperados das ações brasileiras. **Inspere**, v. 195, p. 27, 2009. Disponível em: <https://repositorio.insper.edu.br/handle/11224/5801>. Acesso em: 25 jun. 2024.

DUMITRESCU, Elena; HUÉ, Sullivan; HURLIN, Christophe; *et al.* Machine Learning for Credit Scoring: Improving Logistic Regression with Non-Linear Decision-Tree Effects. **European Journal of Operational Research**, v. 297, n. 3, 2021. DOI: 10.1016/j.ejor.2021.06.053. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0377221721005695>. Acesso em: 10 jun. 2024.

DURAND, David. **Risk Elements in Consumer Installment Financing**. [S. l.]: NBER Books, 1941.

FEDERAÇÃO BRASILEIRA DE BANCOS (FEBRABAN). Segurança cibernética, Inteligência Artificial e Open Finance são prioridades para os bancos em 2022. **FEBRARAN**, [s. l.], 5 abr. 2022. Disponível em: <https://portal.febraban.org.br/noticia/3781/pt-br/>. Acesso em: 25 jun. 2024.

FERREIRA, João Francisco De Assis. **Análise de Crédito**. 2010. Monografia (Graduação em Ciências Humanas) – Instituto de Ensino Superior de Assis, Fundação Educacional do Município de Assis, Assis, 2010. Disponível em: <https://cepein.femanet.com.br/BDigital/arqTccs/0911260614.pdf>. Acesso em: 10 jun. 2024.

FIALHO, Thawanny Amelia da Silva. **O estudo das Fintechs e seus aspectos positivos, negativos e impactos no Sistema Financeiro Nacional**. 2023. Monografia (Graduação em Administração) – Universidade Estadual de Goiás, Unidade Universitária de Luziânia, Luziânia, 2023. Disponível em: <https://repositorio.ueg.br/jspui/handle/riueg/749>. Acesso em: 10 jun. 2024.

FONTES, Edison Luiz Gonçalves. **Segurança da informação**. São Paulo: Saraiva Educação SA, 2017.

GUNNARSSON, Björn Rafn; BROUCKE, Seppe Vanden; BAESSENS, Bart; *et al.* Deep learning for credit scoring: Do or don't? **European Journal of Operational Research**, v. 295, n. 1, p. 292–305, nov. 2021. DOI: 10.1016/j.ejor.2021.03.006. Disponível em: <https://doi.org/10.1016/j.ejor.2021.03.006>. Acesso em: 10 jun. 2024.

HOOFNAGLE, Chris Jay; VAN DER SLOOT, Bart; BORGESIUUS, Frederik Zuiderveen. The European Union general data protection regulation: what it is and what it means. **Information & Communications Technology Law**, v. 28, n. 1, p. 65–98, 2019. DOI: 10.1080/13600834.2019.1573501. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/13600834.2019.1573501>. Acesso em: 10 jun. 2024.

HULL, John; WHITE, Alan. **Hull-White on Derivatives: A Compilation of Articles** by John Hull and Alan White. London: Risk Publications, 1996.

HULL, John; WHITE, Alan. Valuing Derivatives: Funding Value Adjustments and Fair Value. **Financial Analysts Journal**, v. 70, n. 3, p. 46–56, maio 2014. DOI: 10.2469/faj.v70.n3.3. Disponível em: <https://doi.org/10.2469/faj.v70.n3.3>. Acesso em: 10 jun. 2024.

INSTITUTO DOS AUDITORES INTERNOS DO BRASIL (IIA BRASIL). **Declaração de posicionamento do IIA: as três linhas de defesa no gerenciamento eficaz de riscos e controles**. São Paulo: The Institute of Internal Auditors, 2013. Disponível em: <https://repositorio.cgu.gov.br/handle/1/74060>. Acesso em: 10 jun. 2024.

INTERNATIONAL MONETARY FUND (IMF). **Global Financial Stability Report: Navigating the Financial Challenges Ahead**. Washington, DC: International Monetary



Fund, 2009. Disponível em:  
<https://www.imf.org/en/Publications/GFSR/Issues/2016/12/31/Global-Financial-Stability-Report-October-2009-Navigating-the-Financial-Challenges-Ahead-22584>.  
Acesso em: 10 jun. 2024.

INTERSOFT CONSULTING. Intersoft Consulting. **Intersoft Consulting**, [s. l., s. d.].  
Disponível em: <https://www.intersoft-consulting.de/en/>. Acesso em: 10 jun. 2024.

**ISO.Space data and information transfer systems-audit and certification of trustworthy digital repositories**: ISO 16363. [S. l.]: ISO, 2012.

JARROW, Robert A; RUDD, Andrew. **Option Pricing**. [S. l.]: McGraw-Hill/Irwin, 1983.

JESUS, Regilson Vasconcellos; SILVA, Daniel Alves da; TORRES, José Alberto Souza *et al.* Open Source Intelligence: Classification and Mitigation of Risks and Fraud Within Financial Institutions. *In*: 2023 18TH IBERIAN CONFERENCE ON INFORMATION SYSTEMS AND TECHNOLOGIES (CISTI), 2023 Aveiro, Portugal. **Anais** [...]. [S. l.]: IEEE, 2023. p. 1-5. DOI: 10.23919/CISTI58278.2023.10211291. Disponível em: <https://ieeexplore.ieee.org/document/10211291>. Acesso em: 22 jun. 2024.

JORION, Philippe. **Financial Risk Manager Handbook**. 5. ed. Hoboken, NY: Wiley, 2009. 752 p.

KEOWN, Arthur J.; MARTIN, John D. **Financial Management: Text and Cases**. 13. ed. [S. l.]: Pearson Prentice Hall, 2014.

KOBO, Beatriz YUMI. OPEN FINANCE E SUA REGULAMENTAÇÃO NO BRASIL; Desafios e Oportunidades. P 42, 2023. BACHARELADO EM DIREITO, São Paulo, 2023. Disponível em:  
[https://repositorio.pucsp.br/bitstream/handle/40986/1/Beatriz%20Kobo%20-%20TCC\\_Beatriz%20Yumi%20Kobo.pdf](https://repositorio.pucsp.br/bitstream/handle/40986/1/Beatriz%20Kobo%20-%20TCC_Beatriz%20Yumi%20Kobo.pdf). Acesso em: 22 jun. 2024.

LANDO, David. Credit Risk Modeling. *In*: MIKOSCH, T; KREISS, J. P.; DAVIS, R; *et al* (Orgs.). **Handbook of Financial Time Series**. Springer, Berlin, Heidelberg: Springer, 2009, p. 787–798. DOI: 10.1007/978-3-540-71297-8\_35. Disponível em: [https://doi.org/10.1007/978-3-540-71297-8\\_35](https://doi.org/10.1007/978-3-540-71297-8_35). Acesso em: 22 jun. 2024.

MONTEIRO, Renato Leite. **Existe um direito à explicação na Lei Geral de Proteção de Dados Pessoais do Brasil?** Rio de Janeiro: Instituto Igarapé, 2018. Disponível em: <https://igarape.org.br/wp-content/uploads/2018/12/Existe-um-direito-a-explicacao-na-Lei-Geral-de-Protacao-de-Dados-no-Brasil.pdf>. Acesso em: 22 de jun. 2024.

LESSMANN, S. *et al.* Benchmarking state-of-the-art classification algorithms for credit scoring: An update of research. **European Journal of Operational Research**,

v. 247, n. 1, p. 124–136, nov. 2015. DOI: 10.1016/j.ejor.2015.05.030. Disponível em: <https://doi.org/10.1016/j.ejor.2015.05.030>. Acesso em: 22 jun. 2024

LINDSTRÖM, Erik; MADSEN, Henrik; NIELSEN, Jan Nygaard. **Statistics for Finance**. 1. ed. New York: Chapman and Hall/CRC, 2018. DOI: 10.1201/9781315372204. Disponível em: <https://doi.org/10.1201/9781315372204>. Acesso em: 20 jun. 2024.

LINTNER, John. The Valuation of Risk Assets and the Selection of Risky Investments in Stock Portfolios and Capital Budgets. **The Review of Economics and Statistics**, v. 47, n. 1, p. 13–37, mar. 1965. DOI: 10.2307/1924119. Disponível em: <https://doi.org/10.2307/1924119>. Acesso em: 22 jun. 2024.

MARKOWITZ, Harry. Portfolio Selection. **The Journal of Finance**, v. 7, n. 1, mar. 1952. DOI: 10.2307/2975974. Disponível em: <https://www.jstor.org/stable/2975974>. Acesso em: 19 jun. 2024.

MECANISMO ONLINE PARA REFERÊNCIAS. **MORE**, [s. /., s. d.]. Disponível em: <https://more.ufsc.br/>. Acesso em: 22 jun. 2024.

MERTON, Robert C. On the Pricing of Corporate Debt: The Risk Structure of Interest Rates. *The Journal of Finance*, v. 29, n. 2, p. 449–470, maio 1974. DOI: 10.1111/j.1540-6261.1974.tb03058.x .Disponível em: <https://doi.org/10.1111/j.1540-6261.1974.tb03058.x>. Acesso em: 25 jun. 2024

MONTEIRO, Yasmin Sousa. **A efetividade dos mecanismos de proteção de ados pessoais na lei 12.709/2018**. 2019. Monografia (Bacharel em Direito) – Faculdade de Ciências Jurídicas e Sociais, Centro Universitário de Brasília, Brasília, 2019. Disponível em: <https://repositorio.uniceub.br/jspui/handle/prefix/13383>. Acesso em: 25 jun. 2024.

MOYER, Charles R.; MCGUIGAN, James R.; RAO, Ramesh K. S. **Contemporary financial management**. Boston: Cengage Learning, 2018.

NEWMAN, Lily Hay. What Twitter’s 200 Million-User Email Leak Actually Means. **WIRED**, 6 jan. 2023. Disponível em: <https://www.wired.com/story/twitter-leak-200-million-user-email-addresses/>. Acesso em: 22 jun. 2024.

OLIVEIRA, Lucas Gabriel de. Transformação do setor financeiro brasileiro: o impacto das fintechs na oferta de produtos e serviços sob perspectivas tecnológicas e sociais. 2023. 21 f. Trabalho de Conclusão de Curso (Bacharelado em Administração) – Departamento de Administração, Universidade Federal Rural de Pernambuco, Recife, 2023. Disponível em: <https://repository.ufrpe.br/handle/123456789/5282>. Acesso em: 22 jun. 2024.

PACETE, Luiz Gustavo. 5 ataques cibernéticos no Brasil em 2021 que geraram alerta. **Forbes Brasil**, [s. /.], 31 dez. 2021. Disponível em: <https://forbes.com.br/forbes-tech/2021/12/5-ataques-ciberneticos-no-brasil-em-2021-que-geraram-alerta>. Acesso em: 25 maio 2024.

PAPOUSKOVA, Monika; HAJEK, Petr. Two-stage consumer credit risk modelling using heterogeneous ensemble learning. **Decision Support Systems**, v. 118, p. 33–45, mar. 2019. DOI: 10.1016/j.dss.2019.01.002. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0167923619300028>. Acesso em: 20 jun. 2024.

PINHEIRO, Patrícia Peck. **Proteção de dados pessoais**: Comentários à lei n. 13.709/2018-(LGPD). São Paulo: Saraiva Educação SA, 2020.

RAPÔSO, Cláudio Filipe Lima; LIMA, Haniel Melo de; OLIVEIRA JUNIOR, Waldecy Ferreira de *et al.* LGPD - LEI GERAL DE PROTEÇÃO DE DADOS PESSOAIS EM TECNOLOGIA DA INFORMAÇÃO: Revisão Sistemática. **RACE - Revista de Administração do Cesmac**, [s. l.], v. 4, p. 58–67, 2019. DOI: 10.3131/race.v4i0.1035. Disponível em: <https://revistas.cesmac.edu.br/administracao/article/view/1035>. Acesso em: 18 jun. 2024.

REUTERS. Netshoes no Brasil confirma que sofreu ataque cibernético e dados de clientes foram revelados. **G1**, 17 ago. 2018. Disponível em: <https://g1.globo.com/economia/noticia/netshoes-no-brasil-confirma-que-sofreu-ataque-cibernetico-e-dados-de-clientes-foram-revelados.ghtml>. Acesso em: 18 jun. 2024.

ROKACH, Lior; SCHCLAR, Alon; ITACH, Ehud. Ensemble methods for multi-label classification. **Expert Systems with Applications**, v. 41, n. 16, p. 7507–7523, 15 nov. 2014. DOI: 10.1016/j.eswa.2014.06.015. Disponível em: <https://doi.org/10.1016/j.eswa.2014.06.015>. Acesso em: 26 dez. 2023.

ROSS, Stephen A; WESTERFIELD, Randolph; JAFFE, Jeffrey F. **Corporate finance**. 3. ed. New York: Mcgraw-Hill/Irwin, 2013.

SANTANA, Ivone. Brazil has second highest fraud rate in world, Visa says. **Valor Internacional**, São Paulo, 27 dez. 2023. Disponível em: <https://valorinternational.globo.com/business/news/2023/12/27/brazil-has-second-highest-fraud-rate-in-world-visa-says.ghtml>. Acesso em: 25 jun. 2024.

SANTOS, José Odálio dos; SANTOS, José Augusto Rodrigues dos. O Modelo KMV e sua utilidade no processo de análise do Risco de Crédito. **Revista de Gestão**, v. 16, n. 2, p. 73–82, abr./ago. 2009. Disponível em: <https://congressosp.fipecafi.org/anais/artigos42004/87.pdf>. Acesso em: 25 jun. 2024.

SANTOS, Eduardo Esteves dos; SOARES, Tamires Mariana Mayumi Kurosaki . Riscos, ameaças e vulnerabilidades: O impacto da segurança da informação nas organizações. **Revista Tecnológica da Fatec Americana**, v. 7, n. 2, p. 43–51, 2019. Disponível em: <https://www.fatec.edu.br/revista/index.php/RTecFatecAM/article/view/188>. Acesso em: 22 jun. 2024.

SILVA, Elisângela Freitas da; FREITAS JUNIOR, Nilton; TAVARES, Leandra Viera Viana *et al.* Open Banking: uma inovação no sistema financeiro. **REVES - Revista Relações Sociais**, [s. l.], v. 6, n. 2, p. 16168–01e, 2023. DOI: 10.18540/revesv6iss2pp16168-01e. Disponível em: <https://periodicos.ufv.br/reves/article/view/16168>. Acesso em: 20 jun. 2024.

STEELE, Robert David. The accountability of security and intelligence agencies. *In*: JONHSON, Loch K. (Org.). **Handbook of Intelligence Studies**. Nova York, NY: Routledge, 2007, p. 85–99.

TRAC METRICS. Trustworthy repositories audit certification criteria and checklist **TRAC**, 2007. Disponível em: <<https://www.crl.edu/archiving-preservation/digital-archives/metrics-assessing-and-certifying/trac>>. Acesso em: 20 jun. 2024.

T-MOBILE says its investigating data breach affecting 37 million accounts. **CNBC**, 19 jan. 2023. Disponível em: <https://www.cnbc.com/2023/01/19/t-mobile-investigating-data-breach-affecting-37-million-accounts.html>. Acesso em: 13 fev. 2024.

TSAI, Chih-Fong; HSU, Yu-Feng; YEN, David C. A comparative study of classifier ensembles for bankruptcy prediction. **Applied Soft Computing**, v. 24, p. 977–984, 1 nov. 2014. DOI: 10.1016/j.asoc.2014.08.047. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S1568494614004128>. Acesso em: 22 jun. 2024.

UEDA, Marcos. Desafios regulatórios no setor financeiro: uma análise das transformações promovidas por fintechs no mercado de meios de pagamento no Brasil. **Revista de Defesa da Concorrência**, v. 11, n. 2, p. 143–171, 2023. DOI: 10.52896/rdc.v11i2.1068. Disponível em: <https://revista.cade.gov.br/index.php/revistadedefesadaconcorrencia/article/view/1068>. Acesso em: 15 abr. 2024.

UNIÃO EUROPEIA (UE). Regulation (Eu) 2016/679 of the European Parliament and of the Council, of 27 April 2016. On the protection of natural persons with regard to the processing of personal data and on the free movement of such data, and repealing Directive 95/46/EC (General Data Protection Regulation). **Official Journal of the European Union**: L119, Brussels, 27 abr. 2016. Disponível em: <https://eur-lex.europa.eu/legal-content/EN/TXT/PDF/?uri=CELEX:32016R0679>. Acesso em: 20 jun. 2024.

UNIÃO EUROPEIA (UE). **Manual da Legislação Europeia sobre Proteção de Dados**. Luxemburgo: Serviço das Publicações da União Europeia, 2022. Disponível em: <https://fra.europa.eu/pt/publication/2022/manual-da-legislacao-europeia-sobre-protecao-de-dados-edicao-de-2018>. Acesso em: 20 jun. 2024.

UNIÃO EUROPEIA (UE). **GDPR Enforcement Tracker Report**. [S. l.]: 2024. Disponível em <https://cms.law/en/int/publication/gdpr-enforcement-tracker-report?format=pdf>. Acesso em: 20 jun. 2024.

WORLD BANK. **General Principles for Credit Reporting**. Washington, DC: World Bank, 2011. Disponível em: <https://documents1.worldbank.org/curated/en/662161468147557554/pdf/70193-2014-CR-General-Principles-Web-Ready.pdf>. Acesso em: 20 jun. 2024.

XIA, Yufei; WU, Jie; WEI, Wei *et al.* Exploiting the pliability and lateral mobility of Pickering emulsion for enhanced vaccination. **Nature Materials**, v. 17, n. 2, p. 187–194, 4 jan. 2018. DOI: 10.1038/nmat5057. Disponível em: <https://www.nature.com/articles/nmat5057>. Acesso em: 20 jun. 2024.

ZHEN-SONG, Chen; ZHOU, Jia; ZHU, Chen-Ye; *et al.* Prioritizing real estate enterprises based on credit risk assessment: an integrated multi-criteria group decision support framework. **Financial Innovation**, v. 9, 11 out. 2023. DOI: 10.1186/s40854-023-00517-y. Disponível em: <https://doi.org/10.1186/s40854-023-00517-y>. Acesso em: 21 dez. 2023.

ZULIANI, Matheus Stamillo Santarelli. *Score de crédito só pode judicializado se empréstimo foi negado*. **Conjur**, [S. l.], 21 maio, 2017. Disponível em: <https://www.conjur.com.br/2017-mai-21/score-credito-judicializado-emprestimo-foi-negado/#author>. Acesso em: 22 jun. 2024.