

# Complaint Analysis in Digital Banks: Topic Modeling Based on Large Language Model

Pedro C. Menezes<sup>1</sup>, Fabrício A. do Carmo<sup>1,2</sup>, Ricardo M. Maracini<sup>3</sup>,  
Antonio F. L. Jacob Junior<sup>2</sup>, Fábio M. F. Lobato<sup>1,2</sup>

<sup>1</sup>Instituto de Engenharia e Geociências  
Universidade Federal do Oeste do Pará – Santarém – PA – Brazil

<sup>2</sup>Departamento de Engenharia da Computação  
Universidade Estadual do Maranhão – São Luís – MA – Brazil

<sup>3</sup>Instituto de Ciências Matemáticas e de Computação  
Universidade de São Paulo – São Carlos – SP – Brazil

antoniojunior@professor.uema.br, fabio.lobato@ufopa.edu.br

**Abstract.** *Advances in the field of fintechs have had a significant impact on the context of financial services. Consequently, there has been an increase in the number of complaints related to this sector. In this context, the aim of this paper is to collect and analyze complaints related to Fintechs, using Topic Modeling techniques combined with large language models. We analyzed 1,427 complaints linked to the four main Brazilian digital banks, namely: Nubank, PicPay, Banco-Inter and C6-Bank. The results showed that problems related to credit cards are more common in consumer reports. Thus, the information uncovered can provide opportunities for fintechs to remain aware of the main adversities faced and the perception of the services provided from the customer's point of view.*

**Resumo.** *O avanço no domínio das Fintechs tem impactado significativamente o contexto dos serviços financeiros. Consequentemente, observa-se um crescimento na quantidade de reclamações relacionadas a esse setor. Nesse contexto, o objetivo do presente trabalho é coletar e analisar reclamações relacionadas as Fintechs, utilizando de técnicas de Modelagem de Tópicos aliada aos grandes modelos de língua. Foram analisadas 1.427 reclamações vinculadas aos quatro principais bancos digitais brasileiros, a saber: Nubank, PicPay, Banco-Inter e C6-Bank. Os resultados destacaram que problemas relacionados a cartões de crédito, possuem maior recorrência nos relatos dos consumidores. As informações descobertas podem prover oportunidades as Fintechs em se manter cientes das principais adversidades enfrentadas e percepção dos serviços prestados sob à ótica do cliente.*

## 1. Introdução

A demanda por produtos que sejam inovadores e capazes de fornecer usabilidade e rapidez a operações rotineiras tem se tornado tendência mundial [Pereira et al. 2023]. O termo “Fintech” é oriundo da combinação entre dois termos em inglês: *financial* (finanças) e *technology* (tecnologia). Nesse sentido, Fintech corresponde a empresas capazes de aliar

serviços financeiros e tecnologia, tanto para pessoas físicas quanto para pessoas jurídicas [de Mattos and Guedes 2019]. Desse modo, o financeiro digital vem ganhando notoriedade ao longo dos anos, uma vez que as Fintechs conseguem facilitar ações cotidianas, já que disponibiliza diversos serviços diretamente nas telas dos computadores pessoais e *smartphones* [Diniz 2020].

Com o crescimento das Fintechs, as redes sociais assumem um papel crucial na forma como as empresas interagem com seus clientes, impactando as estratégias de *Customer Relationship Management* (CRM) [Do Carmo et al. 2024]. Além disso, as mídias sociais transformaram a maneira como os usuários expressam suas opiniões, permitindo que outros avaliem produtos e serviços com base nas experiências compartilhadas pela comunidade de consumidores [Voramontri and Klieb 2019]. Nesse contexto, surgem plataformas especializadas em resolução de reclamações, conhecidas como *Online Dispute Resolution* (ODR), que podem incluir ações jurisdicionais e extrajurisdicionais, como é o caso do Consumidor.Gov [Guerra and Salinas 2020].

A plataforma Consumidor.Gov<sup>1</sup>, atualmente, é considerada uma das ferramentas mais influentes no cenário brasileiro atual. Nesse sentido, o Consumidor.Gov atua como via de comunicação entre consumidores e as grandes corporações, na qual os usuários podem relatar suas reclamações e opiniões sobre um determinado produto ou serviço [Silva et al. 2024]. Desde 2020, mais de 1 milhão de reclamações são processadas por ano, com mais 80% de resolubilidade [Ministério da Justiça e Segurança Pública 2024]. Logo, essas informações são de suma importância para as empresas, tendo em vista que as reclamações possuem o potencial de evidenciar as principais lacunas de produtos e serviços [Singh et al. 2022].

Devido à enorme quantidade de reclamações, torna-se inviável utilizar recursos humanos para realizar as análises [Silva et al. 2024]. Sob essa ótica, o uso de técnicas de Aprendizado de Máquina e Processamento de Linguagem Natural (PLN) (*e.g.*, modelagem de tópicos) mostram-se abordagens promissoras. À luz do contexto apresentado, o objetivo do presente estudo consiste em analisar reclamações relacionadas as Fintechs utilizando métodos de PLN. Foram analisadas 1.427 reclamações coletadas da plataforma Consumidor.Gov. As análises foram conduzidas utilizando as técnicas de modelagem de tópicos usando *Large Languages Models* (LLMs), visto que compreende a fronteira do estado da arte.

O restante deste artigo está organizado como segue. Na Seção 2 é apresentado os trabalhos relacionados à pesquisa. Por seguinte, a Seção 3 descreve os materiais e métodos usados no presente trabalho. Os resultados e *insights* construídos por meio das análises são apresentados na Seção 4. Por fim, a Seção 5 apresenta as considerações finais e trabalhos futuros.

## 2. Trabalhos Relacionados

Diversos estudos com foco na análise de reclamações têm explorado técnicas de mineração de texto. Os autores de [Vairetti et al. 2024] propuseram a criação de um *framework* a fim de automatizar a rotulação e priorização de reclamações, por meio de técnicas de análise de texto e *Operational Research* (OR). Para etapa de rotulação foi utilizado uma abordagem de Tomada de Decisão com base em Múltiplos Critérios, a medida

---

<sup>1</sup><https://consumidor.gov.br>

que para etapa de priorização empregou-se o BETO, um modelo de *word embeddings* baseado no *Bidirectional Encoder Representations from Transformers* (BERT), treinado a partir de grande conjunto de textos em espanhol. As reclamações foram classificadas conforme o nível de prioridade (urgentes e outras). Os resultados do experimento mostraram-se promissores, com a acurácia de 92,1% e área sob a curva de 0,98. O presente trabalho busca a ampliação do uso das técnicas de PLN mais avançadas, tais como LLMs e modelagem de tópicos.

[Wang et al. 2023] desenvolveram uma nova abordagem chamada PromptTopic, que utiliza as avançadas capacidades de entendimento linguístico que as LLMs proporcionam para a modelagem de tópicos. O modelo proposto consiste em 3 etapas: i) geração dos tópicos; ii) colapso de tópicos; iii) geração da representação de tópicos. Os 3 estágios utilizam a LLM para extrair, organizar e refinar os tópicos. A abordagem foi avaliada utilizando 3 *dataset* comumente utilizados para tarefa de modelagem de tópicos: *News-Group*, *Yelp Reviews*; *Twitter Tweet*. Os resultados alcançados mostram-se competitivos quando comparados aos *baselines*. Assim, [Wang et al. 2023] evidencia que os recursos que as LLMs proporcionam são pertinentes para tarefa de modelagem de tópicos, uma vez que, a abordagem PromptTopic elimina a etapa de ajuste dos hiperparâmetros e podem gerar tópicos mais legíveis ao humano.

[Das et al. 2024] focaram na priorização das reclamações financeiras a partir de estruturas hierárquicas. Os autores propuseram a criação de um *framework* baseado em *Hierarchical Attention* (HAtt) constituído de 5 etapas, a saber: i) classificação binária das reclamações; ii) reconhecimento de emoções; iii) categorização do sentimento; iv) extração das causas; v) classificação do nível de severidade. O modelo construído alcançou 93,58% de acurácia e 92,58% de *F1-score*. Além disso, o modelo auxilia na interpretabilidade das reclamações, uma vez que, possui etapas específicas para o entendimento das causas e sentimentos. Almejando dar continuidade a propor fácil interpretabilidades aos resultados dos modelos, o presente estudo foca no uso de LLM, não só para facilitar a tarefa de modelagem de tópicos, mas também visa a alcançar resultados mais legíveis e interpretáveis ao ser humano.

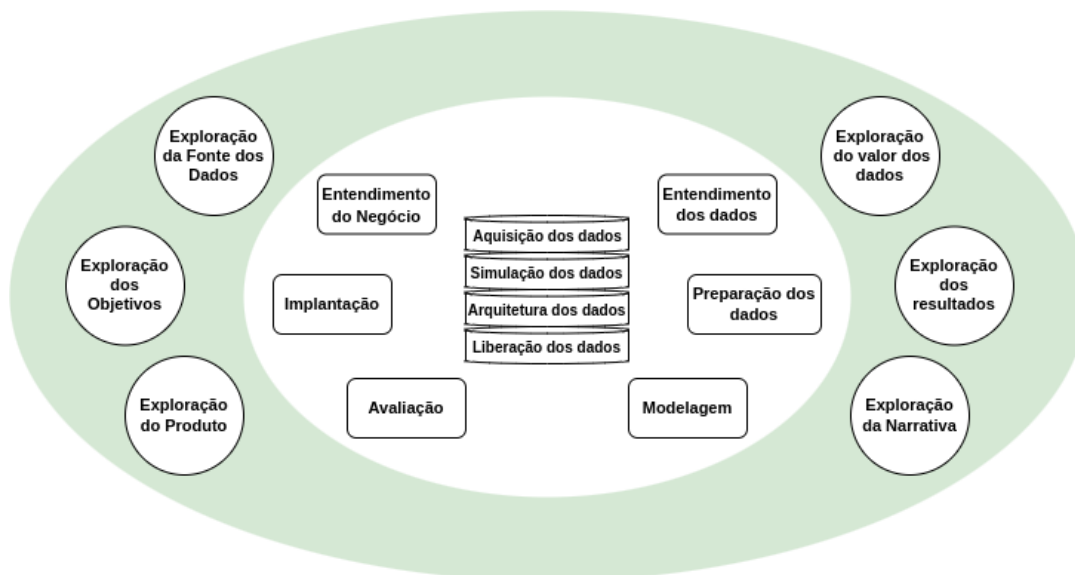
[Khadija and Nurharjadmo 2024] propuseram uma abordagem de hibridação entre o BERT e o algoritmo de modelagem de tópicos *Latent Dirichlet Allocation* (LDA). Os resultados mostram-se promissores em reclamações escritas no idioma indonésio. Assim sendo, a combinação proposta apresentou resultados de coerência e silhueta superiores quando comparados a abordagem LDA tradicional. Visando atualizar os métodos e materiais utilizados, o presente trabalho inclui técnicas modelagem de tópicos usando LLMs e o método de pesquisa *Data Science Trajectories* (DST).

Por meio da análise dos trabalhos correlatos, evidenciou-se o potencial que as técnicas de mineração de texto possuem como ferramenta para análise de reclamações em diversas esferas, a fim de construir valor a partir dessas informações. Outrossim, os estudos evidenciam as técnicas da modelagem de tópico como bons meios para construção de conhecimento, entendimento da posição de mercado das empresas e percepção dos clientes. No entanto, nota-se uma escassez de trabalhos com foco na análise de reclamações no domínio das Fintechs. Embora os estudos utilizem abordagens para modelagem de tópicos e métodos de pesquisa voltados a mineração de dados, percebe-se a falta do emprego de tecnologias mais recentes e metodologias atuais que se adaptem ao escopo da

pesquisa. Dessa forma, o diferencial desse trabalho consiste em preencher essas lacunas da literatura por meio de uma análise de reclamações utilizado uma base de dados com 1.427 registros relacionados aos quatro principais bancos digitais do Brasil: Nubank, C6-Bank, PicPay e Banco Inter. Utilizou-se abordagem de modelagem de tópicos utilizado as tecnologias mais recentes na esfera das LLMs aliada ao método de pesquisa DST, por permitir maior flexibilidade ao pesquisador em escolher as etapas do projeto.

### 3. Materiais e Métodos

O método de pesquisa chamado *Data Science Trajectories* (DST) foi empregado devido a sua flexibilidade em se adequar a diferentes domínios. Esse modelo consiste em uma remodelagem do tradicional *Cross-Industry Standard Process for Data Mining* (CRISP-DM), metodologia de pesquisa voltada a área de *Data Mining* (DM) bem estabelecida na literatura [Wirth and Hipp 2000]. Enquanto o CRISP-DM possui seis etapas, a saber: entendimento do negócio, entendimento dos dados, preparação dos dados; modelagem; avaliação; implantação, o DST possui, além das etapas tradicionais do CRISP-DM, dez processos de cunho exploratório e gerência da informação apresentados na Figura 1, a título de exemplo: Exploração dos Objetivos, Exploração da Fonte dos Dados; Exploração do Valor dos Dados; Exploração dos Resultados; Exploração da Narrativa; Exploração do Produto, Aquisição dos Dados; Simulação dos Dados; Arquitetura dos Dados; Liberação dos Dados. Assim sendo, a metodologia se adequa aos contextos atuais, uma vez que, a Ciência de Dados está tendendo a nuances mais exploratórias e centrada aos dados [Martínez-Plumed et al. 2019].



**Figura 1. Fases do método DST. Adaptado de [Martínez-Plumed et al. 2019]**

O DST permite que o percurso do projeto seja definido pelo pesquisador(a), ao modo que há liberdade de incluir ou retirar determinadas etapas do método de pesquisa. Na presente pesquisa foram utilizados as seguintes etapas: Entendimento do Negócio; Aquisição dos Dados; Entendimento dos Dados; Preparação dos Dados; Modelagem; Avaliação; Exploração dos Resultados. Assim sendo, a instanciação do DST será evidenciada nas Subsecções seguintes.

### 3.1. Entendimento do Negócio

Na primeira etapa, o foco é o entendimento do domínio da aplicação. Desse modo, foi essencial identificar o problema de pesquisa e entender os objetivos a serem alcançados. Para tal, uma revisão da literatura na esfera da análise de reclamações foi conduzida, a fim de reunir as principais informações sobre técnicas utilizadas, métodos de pesquisa e potenciais lacunas acadêmicas, os resultados são evidenciados na Seção 2. É válido ressaltar que nessa etapa inicial foram definidas as principais decisões de projeto, indicados na Tabela 1.

**Tabela 1. Decisões de Projeto adotadas na Etapa 3.1**

<b>Decisão Metodológica</b>	<b>Alternativa Escolhida</b>
Fonte dos Dados	Consumidor.gov
Técnica de PLN	Modelagem de Tópicos
Abordagem de <i>Machine Learning</i>	<i>Large Languages Models (LLMs)</i>
Método para Avaliação dos Resultados	<i>Grounded Theory</i>

Por meio dessa informação, os autores nortearam a definição do objetivo de pesquisa e as devidas metas a serem alcançadas ao longo do projeto, tais como: construir uma ferramenta de raspagem de reclamação para plataforma Consumidor.gov; aliar as ferramentas de LLM para tarefa de modelagem de tópicos; explorar e avaliar os resultados obtidos sob a ótica qualitativa.

### 3.2. Aquisição dos dados

Como a plataforma Consumidor.Gov não fornece meios para de extração de reclamações, foi necessário desenvolver ferramentas capazes de extrair tais informações de forma eficiente. Assim sendo, um *Web Crawler* foi implementado, na linguagem de programação Python<sup>2</sup>, para realizar a tarefa de raspagem automatizada das reclamações. Os dados obtidos foram coletados e salvos em repositórios locais, tanto no formato de arquivo *Comma-Separated Values (CSV)* quanto *Javascript Object Notation (JSON)*. Foram coletadas 156.630 registros de reclamação relacionados aos 4 maiores bancos digitais do Brasil: Nubank, Banco Inter, C6 Bank; PicPay. Entretanto, é notório pontuar que para realizar as análises, utilizou-se uma amostra de 1.427 devido às limitações computacionais existentes no contexto da construção do presente trabalho. Uma sumarização das informações (atributos) das reclamações coletadas estão presentes na Tabela 2

### 3.3. Entendimento do Dados

Nessa etapa, foi realizada uma análise exploratória inicial dos dados, de modo a gerar conhecimentos prévios em relação ao conjunto utilizado. Assim, é possível consolidar *insights* iniciais com intuito de gerar hipóteses para capturar informações ocultas [Nadali et al. 2011]. Além disso, pode-se identificar potenciais ruídos nos dados, os quais podem impactar no desempenho dos modelos.

É possível visualizar a distribuição dos dados em relação a cada um dos bancos digitais na Tabela 3. A partir de uma leitura inicial dos registros foi possível se familiarizar com as características dos dados, onde notou-se a presença problemas de codificação

<sup>2</sup><https://www.python.org/>

**Tabela 2. Atributos coletados das reclamações do Consumidor.Gov**

<b>Atributo</b>	<b>Descrição</b>
<i>name_company</i>	Nome da empresa ao qual a reclamação é dirigida
<i>report_status</i>	Estado da reclamação
<i>report_text</i>	Descrição realizada pelo usuário
<i>report_date</i>	Data da publicação
<i>report_place</i>	Local da reclamação (Cidade-Estado)
<i>response_company</i>	Resposta da empresa
<i>reponse_company_date</i>	Data da resposta da empresa
<i>service_note</i>	Nota para o serviço
<i>consumer_consideration</i>	Consideração do consumidor

de texto. Esses ruídos podem impactar, significativamente os resultados dos modelos, tornando de extrema importância a etapa seguinte de Preparação dos Dados.

**Tabela 3. Distribuição das Reclamações por Banco Digital**

<b>Banco</b>	<b>Quantidade de Reclamações</b>
Nubank	468
Banco Inter	402
C6-Bank	391
PicPay	166

### 3.4. Preparação dos Dados

Como evidenciado na Subseção 3.3, o conjunto de dados coletado possui alguns problemas de codificação. Para lidar com esse fenômeno foi realizado o processo de codificação das sentenças para “*latin-1*” e, posteriormente, decodificação para “*utf-8*”, obtendo o texto decodificado e livre de erros. Esse procedimento foi empregado nas seguintes colunas: “*name\_company*”; “*report\_status*”; “*report\_text*”; “*reponse\_company*”; “*consumer\_consideration*”; “*report\_place*”.

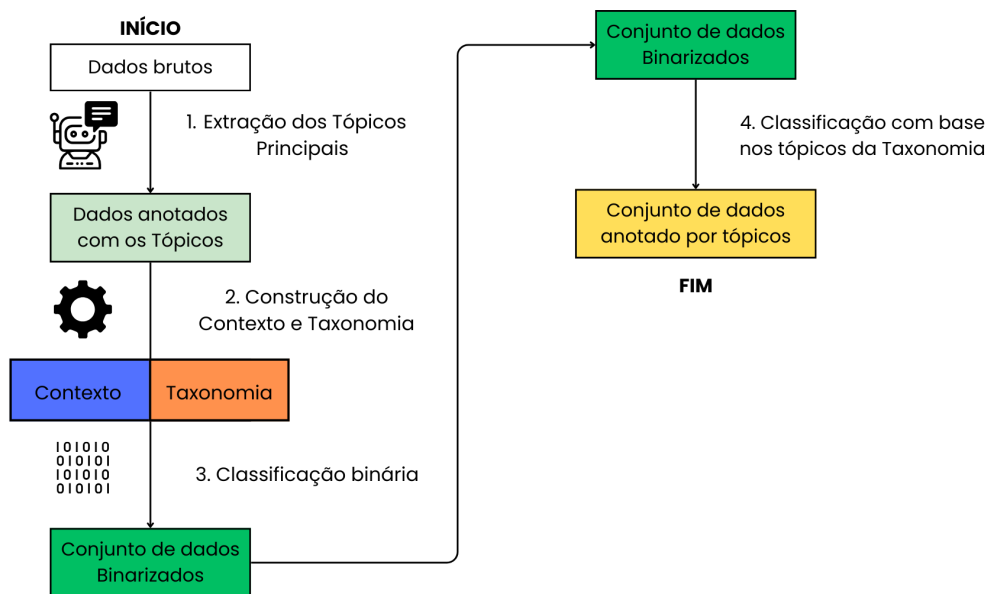
É válido ressaltar que para abordagens de LLMs não é necessário realizar procedimentos de limpeza dos dados, como: remoção de *stopwords*; pontuação; símbolos especiais; uma vez que manter a estrutura do texto é útil, visto que toda a informação é relevante para conectar o contexto em modelos baseados em *transformes* [Egger and Yu 2022].

### 3.5. Modelagem

Para fase de modelagem, utilizou-se o LLM Llama3.1 com 70 bilhões de parâmetros. Esse modelo é construído e disponibilizado pela empresa Meta. O Llama3.1 foi escolhido devido a sua característica multilíngue e capacidade de lidar de forma eficiente com tarefas de sumarização de texto, além do que, consiste em um modelo disponível abertamente<sup>3</sup>.

Avançando na análise, a modelagem de tópicos consiste em uma abordagem amplamente utilizada no PLN empregada para extrair conhecimento de dados textuais não

<sup>3</sup><https://ai.meta.com/blog/meta-llama-3-1/>



**Figura 2. Estágios da modelagem de tópicos com LLM.**

estruturados. Esse método tem como objetivo agrupar documentos e palavras com significados semelhantes [Garcia et al. 2022]. No contexto do presente trabalho, a abordagem de modelagem tópicos utilizando LLM foi organizada em quatro fases, conforme ilustrado na Figura 2. A primeira etapa envolve a extração dos tópicos principais de cada reclamação, para tal é fornecida uma tarefa (*prompt*) específica para LLM capaz de contextualizá-la para o objetivo proposto. A estrutura de “Enviar Tarefas” a LLM se repete nas fases subsequentes, já que a Engenharia de Prompt é crucial para o sucesso da modelagem.

Na segunda fase é realizada a construção do Contexto e Taxonomia com base nos tópicos extraídos na etapa anterior, o modelo identifica os 15 principais tópicos gerais do conjunto de dados (Taxonomia) e gera uma sumarização do *dataset* (Contexto). A terceira etapa consiste na classificação binária (YES ou NO) dos documentos, verificando se o tópico de cada documento pertence ou não ao Contexto e Taxonomia construídos. Após a filtragem, a etapa seguinte consiste em classificar conforme a Taxonomia, ao modo que cada documento é analisado para identificar o tópico mais representativo. Caso não se obtenha resposta, a reclamação recebe a classificação “0 NONE”.

### 3.6. Avaliação

A etapa de avaliação foi baseada na abordagem de *Grounded Theory*, na qual consiste em método de pesquisa qualitativo que permite os pesquisadores discernir processos implícitos e explícitos nos dados. A avaliação consistiu na leitura de uma amostra representativa dos dados, de modo a cruzar a interpretação dos pesquisadores com os resultados obtidos pelo modelo.

Considerando o tamanho da população, foi utilizado 95% de confiança e 5% de erro, resultando em uma amostra de 303 registros escolhidos de forma aleatória. As reclamações foram lidas por completo pelos autores, a fim de validar se o tópico, rotulado

pelo modelo, corresponde à reclamação.

### 3.7. Exploração dos Resultados

Essa etapa tem como objetivo correlacionar as metas de negócio e os resultados de ciência de dados. Os resultados dessa Subseção está representado na Seção 4.

## 4. Resultados

Considerando as configurações experimentais mencionadas na Seção 3, foram analisadas 1.427 registros de reclamações coletadas da plataforma Consumidor.Gov. A Figura 3 apresenta o resultado da construção da Taxonomia, na qual é possível identificar que os 15 tópicos construídos e presentes na Taxonomia abrangem problemas relacionados à gerência de crédito, golpes e fraudes, dificuldade com gerência de conta e empecilhos de CRM.

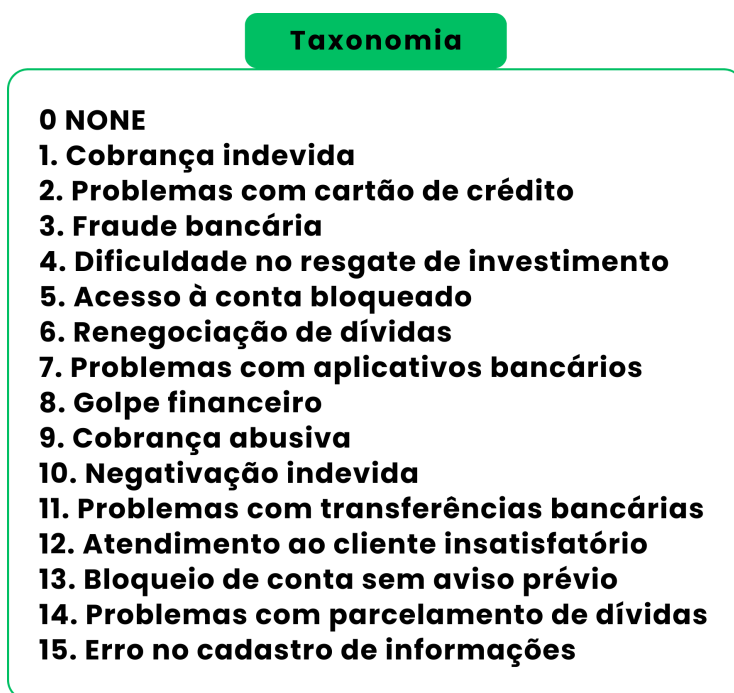


Figura 3. Taxonomia construída por meio da LLM

Em relação ao Contexto, este evidência uma boa sumarização das reclamações presentes no *corpus*, auxiliando na execução das etapas posteriores. Nessa perspectiva, para etapa de classificação binária, 1.227 reclamações foram classificadas como “YES”, por serem consideradas pertencentes ao Contexto, enquanto, 150 reclamações foram classificadas como “NO”. Vale destacar que as reclamações não pertencentes ao Contexto, não foram consideradas nas etapas seguintes.

Em relação ao resultado da modelagem de tópicos, a Tabela 4 evidencia a distribuição do conjunto rotulado conforme a Taxonomia. O tópico **Problemas com cartão de crédito** representa a maioria das reclamações, compreendendo problemas relacionados a compras não reconhecidas, clonagem de cartão e alteração de limite.



**Tabela 4. Resultado da modelagem de tópicos usando LLM**

<b>Tópico</b>	<b>Quantidade</b>
2. Problemas com cartão de crédito	270
1. Cobrança indevida	230
6. Renegociação de dívidas	136
8. Golpe financeiro	84
7. Problemas com aplicativos bancários	60
12. Atendimento ao cliente insatisfatório	56
13. Bloqueio de conta sem aviso prévio	44
11. Problemas com transferências bancárias	33
9. Cobrança abusiva	31
4. Dificuldade no resgate de investimento	31
10. Negativação indevida	30
14. Problemas com parcelamento de dívidas	29
3. Fraude bancária	22
5. Acesso à conta bloqueado	19
15. Erro no cadastro de informações	7

Já os tópicos **Cobrança indevida** e **Cobrança Abusiva** indicam que os clientes dos bancos digitais, enfrentam adversidades referente à cobrança por serviços não prestados e taxas de juros abusivas. Os tópicos **Renegociação de dívidas** e **Problemas com parcelamento de dívidas** mostram que os usuários apresentam dificuldade em negociar dívidas, ou seja, os bancos digitais aparentam ser inflexíveis quanto a sugerir juros mais acessíveis e diferentes formas de pagamentos.

Os tópicos **Golpe financeiro** e **Fraude bancária** mostram que os clientes relatam que foram vítimas de fraudes e golpes, destacando notória lacuna presente nas Fintechs Bancárias ao lidar com esse tipo de problema. **Atendimento ao cliente insatisfatório** evidenciam que os bancos digitais analisados possuem dificuldades em gerir as estratégias de CRM, uma vez que os clientes apontam apresentar dificuldades para entrar em contato com os bancos, falta de respostas às solicitações e atendimento insatisfatório.

Já os tópicos **Problemas com aplicativos bancários** e **Erro no cadastro de informações** destacam que os usuários apresentam problemas técnicos ao utilizar os aplicativos bancários, incluindo dificuldades de acesso à conta e realizar processos simples de cadastro. Os tópicos **Acesso à conta bloqueado**, **Bloqueio de conta sem aviso prévio** e **Negativação indevida** denotam que contas são bloqueadas e negativadas sem nenhum motivo aparente ou por razões não explícitas, isso mostra potenciais falhas de comunicação entre Banco e seus clientes.

O tópico **Problemas com transferências bancárias** implica que os usuários enfrentam problemas ao realizar transações de transferência, incluindo PIX e TED. Já **Dificuldade no resgate de investimento** está relacionado a relatos de cliente com problemas em investimentos, incluindo dificuldades para resgatar valores e omissão das opções.

Sob esse viés, é válido pontuar que foram rotuladas 195 reclamações como “0 NONE”. Porém, essas reclamações foram retiradas para facilitar a visualização dos resultados, conforme explicitado nos Materiais e Métodos. Esse fato destaca que apesar

da Modelagem de Tópicos usando LLM possuir vários benefícios, como: facilidade na implementação e tópicos mais legíveis; é necessário um maior refino do (*prompt*) na etapa de modelagem.

A Figura 4 destaca outra forma de visualização dos resultados da modelagem de tópicos, por meio de grafos. Essa figura foi construída por meio de uma análise de correlação entre os tópicos identificados, na qual cada nó representa uma reclamação e o seu tópico correspondente, enquanto as arestas representam a conectividade entre reclamações semelhantes.

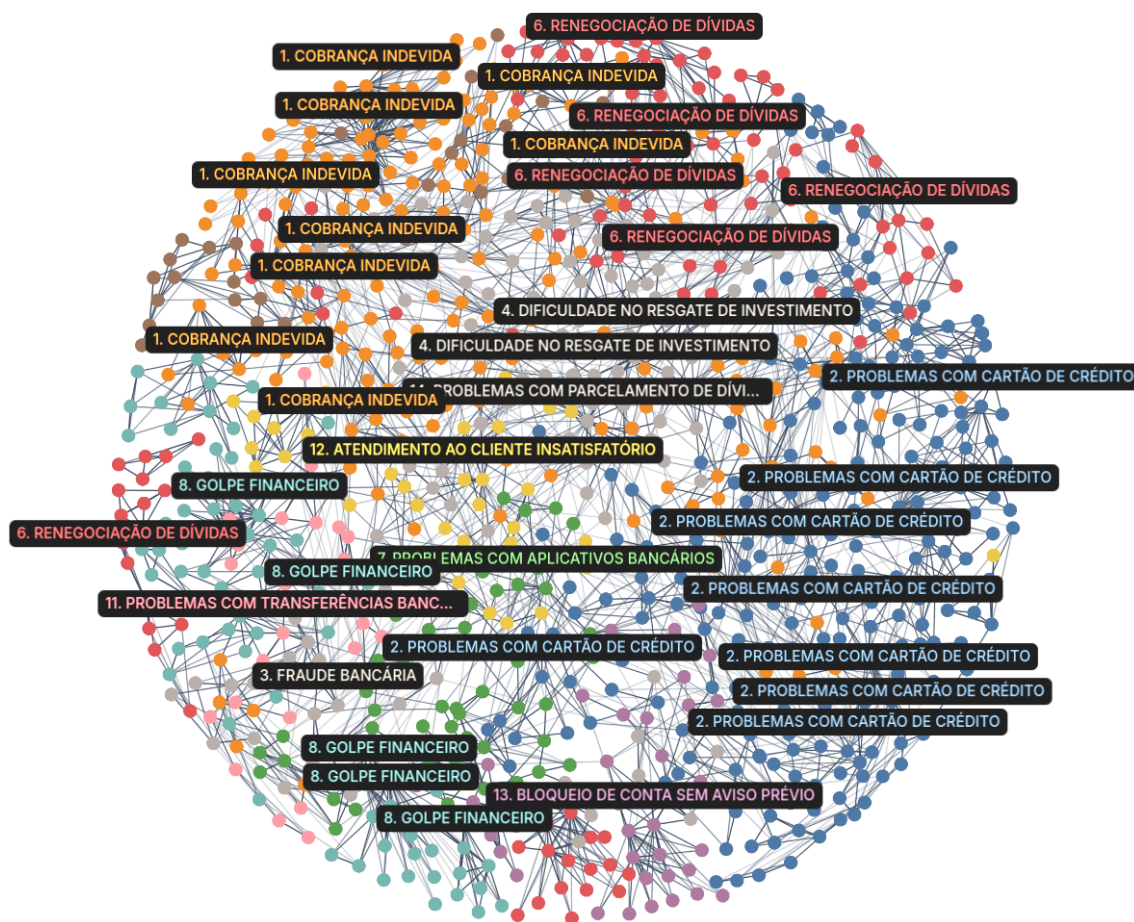


Figura 4. Modelagem de tópicos representada por grafos

Conforme pode ser observado na Figura 4, problemas com relação às cobranças indevidas, cartões de crédito, renegociação de dívidas e golpes financeiros são os principais gatilhos de insatisfação entre os clientes dos bancos digitais, corroborando os achados apresentados na Tabela 4. Em particular, o tópico **Cobrança indevida** possui várias conexões com os tópicos **Renegociação de dívidas** e **Problemas com cartão de crédito**, indicando que muitos clientes enfrentam múltiplas dificuldades simultaneamente, agravando as insatisfações e prejudicando percepção do cliente sobre o banco. Assim, as interconexões entre os tópicos informam que os problemas possuem vínculo, indicando que abordagens de resolução de problemas integrada podem ter impacto significativo na redução das reclamações.

Portanto, os resultados fornecem informações de grande interesse para as Fin-

techs, mais especificamente os bancos digitais, visto que os tópicos extraídos destacam potenciais lacunas relatadas por meio de reclamações dos consumidores. Do ponto de vista gerencial, os resultados podem ser empregados como sistemas de apoio a tomada de decisão na área operacional das empresas, facilitando o direcionamento de recursos para solução de adversidades mais prioritárias, impactando no nível de satisfação dos clientes.

## 5. Considerações Finais

É inegável a atuação do meio digital nos serviços financeiros. Como fruto da integração entre finança e tecnologia, as Fintechs são de suma importância ao promoverem comodidades às ações financeiras cotidianas. Nesse contexto, o presente trabalho apresentou uma análise de reclamações relacionadas as Fintechs, a saber: Nubank, PicPay, Banco Inter e C6-Bank. O diferencial desse estudo é utilizar técnicas de PLN, como modelagem de tópicos, aliada ao uso de LLM, uma vez que estão frente ao estado da arte. Foram coletados e analisados 1.427 registros de reclamações. As análises almejavam destacar potenciais lacunas presentes nos Bancos Digitais.

Os resultados mostraram que parte majoritária das reclamações está relacionada ao tópico de problemas com cartão de crédito. Essa informação se apresenta como potencial guia para tomada de decisão, permitindo que os bancos digitais acessem um panorama dos principais temas de reclamações enfrentados.

Portanto, conclui-se que a aplicação de técnicas de PLN aliadas à LLM são ferramentas capazes de extrair conhecimento das reclamações e auxiliar as empresas, a fim de orientar decisões estratégicas, visando aumentar o nível de satisfação dos consumidores. O atual trabalho apresenta limitações na esfera de especialistas do domínio, uma vez que para interpretação dos resultados obtidos, dado a complexidade do setor de bancos digitais, torna-se necessário um conhecimento profundo do setor financeiro. Nesse sentido, como trabalhos futuros pretende-se integrar o conhecimento de especialistas do domínio para validação dos resultados, refinar o *prompt* de entrada do LLM, avaliar os resultados da modelagem quantitativamente, expandir a amostra analisada e empregar o Llama com 403 bilhões de parâmetros.

## Agradecimentos

Este trabalho foi apoiado pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq)-DT-303031/2023-9; e pela Fundação Amazônia de Amparo a Estudos e Pesquisas (FAPESPA) PRONEM-FAPESPA/CNPq n° 045/2021.

## Referências

- Das, S., Singh, A., Saha, S., and Maurya, A. (2024). Negative review or complaint? exploring interpretability in financial complaints. *IEEE Transactions on Computational Social Systems*.
- de Mattos, C. A. and Guedes, J. V. (2019). Análise de uma fintech a partir da taxonomia de serviços. *Brazilian Journal of Business*, 1(2):356–369.
- Diniz, B. (2020). *O Fenômeno Fintech: Tudo Sobre o Movimento que Está Transformando o Mercado Financeiro no Brasil e no Mundo*. Alta Books.

- Do Carmo, F. A., Menezes, P. H. C., Barata, B. A. P., Jacob, A. F. L., and Lobato, F. M. F. (2024). Crm market overview: A case study of job vacancies. In *Proceedings of the 20th Brazilian Symposium on Information Systems, SBSI '24*, New York, NY, USA. Association for Computing Machinery.
- Egger, R. and Yu, J. (2022). A topic modeling comparison between lda, nmf, top2vec, and bertopic to demystify twitter posts. *Frontiers in sociology*, 7:886498.
- Garcia, J., Villavicencio, G., Altimiras, F., Crawford, B., Soto, R., Minatogawa, V., Franco, M., Martínez-Muñoz, D., and Yepes, V. (2022). Machine learning techniques applied to construction: A hybrid bibliometric analysis of advances and future directions. *Automation in Construction*, 142:104532.
- Guerra, S. and Salinas, N. S. C. (2020). Resolução eletrônica de conflitos em agências reguladoras. *Revista Direito GV*.
- Khadija, M. A. and Nurharjadm, W. (2024). Enhancing indonesian customer complaint analysis: Lda topic modelling with bert embeddings. *SINERGI*, 28(1):153–162.
- Martínez-Plumed, F., Contreras-Ochando, L., Ferri, C., Hernández-Orallo, J., Kull, M., Lachiche, N., Ramírez-Quintana, M. J., and Flach, P. (2019). Crisp-dm twenty years later: From data mining processes to data science trajectories. *IEEE transactions on knowledge and data engineering*, 33(8):3048–3061.
- Ministério da Justiça e Segurança Pública (2024). Consumidor.gov.br - publicações. Acessado em: 21 de agosto de 2024.
- Nadali, A., Kakhky, E. N., and Nosratabadi, H. E. (2011). Evaluating the success level of data mining projects based on crisp-dm methodology by a fuzzy expert system. In *International Conference on Electronics Computer Technology*. IEEE.
- Pereira, R. L., dos Santos Nascimento, A. M., Alves, E. N. A., dos Santos Pontes, E., and Trovão, R. (2023). Brasil e índia: um paralelo sobre o uso de fintech. *Revista Conecta*.
- Silva, D. G., Betker, W. B., Gonçalves, D. P., and Dias, U. S. (2024). Modelos transformers para a análise automática de satisfação na plataforma consumidor. gov. br. In *Workshop de Computação Aplicada em Governo Eletrônico (WCGE)*. SBC.
- Singh, A., Saha, S., Hasanuzzaman, M., and Dey, K. (2022). Multitask learning for complaint identification and sentiment analysis. *Cognitive Computation*, 14(1).
- Vairetti, C., Aránguiz, I., Maldonado, S., Karmy, J. P., and Leal, A. (2024). Analytics-driven complaint prioritisation via deep learning and multicriteria decision-making. *European Journal of Operational Research*, 312(3):1108–1118.
- Voramontri, D. and Klieb, L. (2019). Impact of social media on consumer behaviour. *Int. J. Inf. Decis. Sci.*, 11:209–233.
- Wang, H., Prakash, N., Hoang, N. K., Hee, M. S., Naseem, U., and Lee, R. K.-W. (2023). Prompting large language models for topic modeling. In *2023 IEEE International Conference on Big Data (BigData)*, pages 1236–1241. IEEE.
- Wirth, R. and Hipp, J. (2000). Crisp-dm: Towards a standard process model for data mining. In *Proceedings of the 4th international conference on the practical applications of knowledge discovery and data mining*, volume 1, pages 29–39. Manchester.