

Polarização no YouTube: Interação Colaborativa e a Atração dos Discursos Fortes e Monetização - Proposta de uma Ferramenta Online

Luis Gustavo Almeida¹, Ana Cristina B. Garcia¹, Jefferson Elbert Simões¹

¹ Programa de Pós-Graduação em Informática
Universidade Federal do Estado do Rio de Janeiro (UNIRIO)
Rio de Janeiro – RJ – Brazil
gustavoalmeida@edu.unirio.br
{cristina.bicharra, jefferson.simoese}@uniriotec.br

Abstract. *Social media platforms like YouTube encourage user collaboration through interactions, algorithmic recommendations, and monetization systems, creating an environment conducive to the amplification of polarized and highly engaging discourse. Using public data, we propose a Web Dashboard that automatically collects data (RPA) to analyze the correlation between engagement, monetization, and toxicity on YouTube. By examining how user collaboration drives intense discourse and impacts content moderation, this work contributes to the broader challenges of digital governance and the influence of algorithms in shaping narratives and discourse. Contributions include widgets, charts, tables, and automatic report generation, providing valuable insights for scholars of digital polarization.*

Resumo. *As plataformas de redes sociais, como o YouTube, incentivam a colaboração entre usuários por meio de interações, recomendações algorítmicas e sistemas de monetização, criando um ambiente propício para a amplificação de discursos polarizados e altamente engajadores. Utilizando dados públicos, propomos um Dashboard Web que coleta dados automaticamente (RPA) para analisar a correlação entre engajamento, monetização e toxicidade no YouTube. Ao analisar como a colaboração dos usuários impulsiona discursos intensos e impacta a moderação de conteúdo, este trabalho contribui para os desafios da governança digital e a influência dos algoritmos na formação de discursos e narrativas. As contribuições incluem widgets, gráficos, tabelas e geração automática de relatórios, fornecendo informações para estudiosos da polarização digital.*

1. Introdução

Medir a toxicidade online como por exemplo comentários de vídeos no YouTube, tem se tornado extremamente útil [Guimaraes et al. 2020] para a análise do ecossistema digital. Este trabalho abrange um *Dashboard* Web (conforme ilustrado na Figura 1) em fase de testes e validação, que busca analisar polarização, toxicidade e monetização sobre o ecossistema digital do YouTube.

Polarização política tem sido tópico de interesse nos últimos anos [Guimaraes et al. 2020]. A maioria dos vídeos do YouTube não recebe atenção

significativa, mas aqueles que se destacam, geralmente atingem o pico nos primeiros dias [Bartl 2018]. A popularidade no YouTube é influenciada por fatores externos ao conteúdo, como visualizações anteriores, o tamanho da rede do *uploader* e a idade do vídeo [Bartl 2018].

Os sistemas colaborativos no YouTube, impulsionados por algoritmos de recomendação desempenham um papel crucial na amplificação da polarização e radicalização do conteúdo, e, embora o fato das plataformas adotarem soluções relativas, como denúncias, essas medidas são lentas e limitadas por vieses e recursos [Mariconti et al. 2019]. Conteúdos engajadores têm maior probabilidade de serem promovidos, uma vez que interações entre comunidades e grupos sociais frequentemente resultam em conflitos [Mariconti et al. 2019]. Isso incentiva – e até recompensa financeiramente – a criação de vídeos que provocam reações intensas.

A Web, inicialmente pensada como um meio de acesso à informação, passou por sucessivas fases de ‘economização’, nas quais o engajamento se tornou o motor da economia criativa online [Rieder et al. 2023]. Nesse contexto, o YouTube emerge como uma das principais plataformas de disseminação de conteúdo e formação de opinião pública [Guimaraes et al. 2020], onde a radicalização e a polarização têm se intensificado.

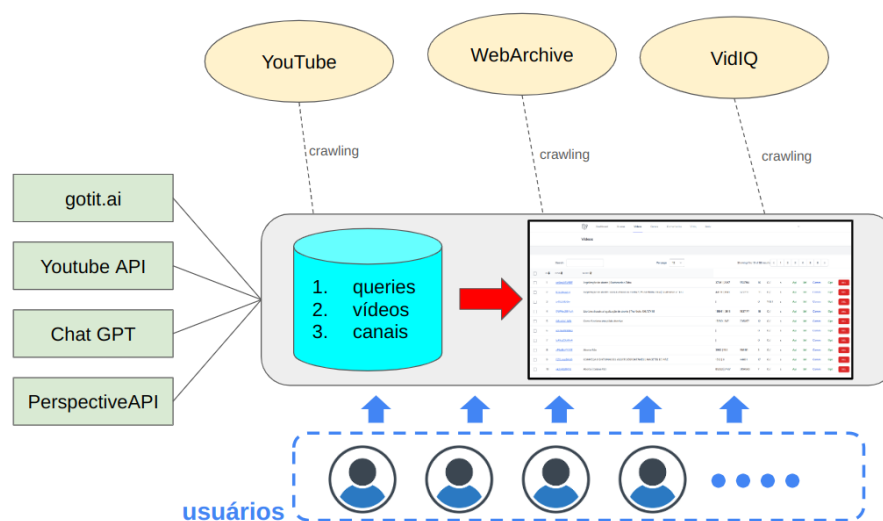


Figura 1. Esquema de arquitetura de coleta de dados do Dashboard Web.

Em artigos acadêmicos os dados coletados sobre o YouTube sugerem que o fornecimento de conteúdo gerado pelo usuário (UGC) cresce, em média, 20% ao ano desde 2006 [Bartl 2018]. No Brasil 79% usam o WhatsApp como principal fonte de notícias [Pereira et al. 2022] e ainda 68% dos americanos e 66% dos brasileiros consomem notícias através de redes sociais [Guimaraes et al. 2020]. Esta ascensão evidencia a interconexão de tais redes e os impactos que podem ter efeitos na sociedade como desinformação, discurso de ódio e polarização.

As redes sociais oferecem um ambiente que facilita a interação colaborativa e a propagação de conteúdos. Recursos como o “compartilhar” ou a URL, podem ser propagados em outros aplicativos. Ao mesmo tempo permitem, através da seção comentários, a interação entre criadores e usuários [Guimaraes et al. 2020]. Um estudo

mostrou que 77,9% das pessoas que comentam sobre notícias o fazem em redes sociais [Guimaraes et al. 2020]. No YouTube o engajamento é ainda maior na medida em que para comentar, basta estar logado, não sendo necessário um vínculo.

A literatura aponta que discurso de ódio e polarização política têm sido amplamente explorados pela comunidade acadêmica [Guimaraes et al. 2020] e são considerados problemas em aberto, especialmente depois de muitos Países aprovarem leis ² com a intenção de mitigar a propagação de conteúdo problemático.

2. Background Acadêmico Teórico

O recurso de comentários, presente em muitas redes sociais, permitem a transformação de usuários leitores passivos para participativos e o motivo mais comum para quem comenta é a expressão de um sentimento [Guimaraes et al. 2020], isso pode transformar a seção comentários em terrenos propícios para toxicidade, fenômeno pelo qual foram extintas a seção comentários dos jornais online [Guimaraes et al. 2020].

A colaboração entre canais e influenciadores tem se tornado um tema de interesse crescente [Zhou et al. 2022]. Além disso, diversos algoritmos de recomendação de conteúdo têm sido desenvolvidos com o objetivo de personalizar a experiência do usuário [Covington et al. 2016]. No entanto, observa-se uma lacuna na literatura quando o foco está na relação entre polarização e monetização.

Fenômenos como *raids* - ataques online de grupos que se coordenam e colaboram para atacar plataformas e usuários com opiniões contrárias ou divergentes (se assemelham a um ataque DDOS) que visam perturbar comunidades [Mariconti et al. 2019], geralmente começam com a postagem de um link em fóruns, incentivando comentários odiosos em vídeos do YouTube. Pesquisas indicam que métricas como “comentários de ódio por segundo” (HCPS) ajudam a identificar ataques ao correlacionar a atividade em fóruns com comentários nos vídeos. Um modelo preditivo para detecção de *raids* foi proposto em [Mariconti et al. 2019]. Baseado em classificadores que analisam metadados, miniaturas e transcrições. Os resultados mostraram excelente eficácia, permitindo a implementação de um sistema de alerta para as plataformas.

Outro fenômeno bem conhecido e discutido academicamente são os filtros de bolha e câmaras de Eco: Algoritmos reforçam opiniões semelhantes dentro de grupos, reduzindo a exposição a perspectivas divergentes e fortalecendo crenças pré-existentes. A tendência de personalização promovida pelos algoritmos de busca tem chamado a atenção para os filtros de bolha, destacando a importância da transparência algorítmica [Pariser 2011].

Os efeitos negativos da colaboração online incluem por exemplo, desinformação e fakenews. Os aplicativos de mensagens contribuem significativamente para o espalhamento de desinformação [Pereira et al. 2022]. A facilidade de se propagar URLs fazem dos aplicativos de mensagens, vetores de disseminação de desinformação. A Covid-19 foi um exemplo que demonstrou a confiabilidade das informações online e impactou a saúde pública [Nogara et al. 2022].

Um grupo denominado ‘Disinfo12’, era composto por 12 indivíduos que foram

²Exemplos: Alemanha - Lei da Rede 2017 (NetzDG), França - Lei da Informação 2018, Singapura (POFMA) 2019 e Brasil - PL 2630 2020 (em processo de aprovação).

responsáveis por aproximadamente 65% da desinformação sobre a Covid-19 nas redes sociais [Nogara et al. 2022]. O artigo explorou suas estratégias de atuação e a metodologia aplicada foi separar *hashtags* em 2 clusters, sendo um sobre desinformação, o qual incluía o ‘Disinfo12’, e o oposto, o ‘Goodinfo’ - um ranking de termos extraídos de empresas de checagem de fatos. Ao aplicar o método *Louvain*, os pesquisadores conseguiram ter acesso a usuários que eram cooptados pelos *clusters*, podendo assim traçar um mapa de rede.

O efeito *Streisand* (fenômeno que ocorre quando a tentativa de censurar ou proibir informações acaba gerando ainda mais divulgação e atenção para o conteúdo censurado) costuma gerar um comportamento inesperado da audiência. Isso acontece quando vídeos removidos ou desmonetizados acabam sendo divulgados massivamente por outros meios. Diferentemente do *clickbait* que é uma estratégia de engajamento com títulos exagerados e/ou enganosos, que podem ser penalizados pelo YouTube.

A comunidade online Intellectual Dark Web (IDW) reúne intelectuais que criticam o politicamente correto, sem apelar ao extremismo. A ‘alt-lite’ adota pautas conservadoras como antifeminismo e crítica à imigração, mas rejeita o racismo aberto. Já a ‘alt-right’ representa a extrema-direita radical. A ‘Manosphere’ reúne comunidades antifeministas como ‘incells’, ativistas pelos direitos dos homens (MGTOW) e artistas de paquera (pickup artists). Esses canais conseguem, por meio de subterfúgios, explorar formas alternativas de monetização, contornando o sistema de moderação da plataforma e desafiando os mecanismos de monetização nativa [Hua et al. 2022].

A trajetória da plataforma foi marcada por acontecimentos delicados, como o ‘Apocalypse’ de 2017, quando anunciantes se retiraram após descobrirem seus anúncios vinculados a conteúdos extremistas [Zappin et al. 2022, Hua et al. 2022, Andres et al. 2023]. Outras situações problemáticas incluem o fenômeno ‘Reply girl’, que explorava sexualização para atrair cliques, levando o YouTube a reformular seu algoritmo em 2019. No entanto, o desafio de moderação persiste diante do volume massivo de uploads (cerca de 500 horas por minuto) [Andres et al. 2023].

Uma caracterização das estatísticas do YouTube em um recorte de 10 anos (2006 a 2016), concluiu que 3% dos canais respondem por 85% das visualizações com 20% do total de *uploads* [Bartl 2018]. O estudo aponta a vantagem do pioneirismo dando evidências para a contribuição do fenômeno “ricos ficam mais ricos” [Bartl 2018].

Apesar de existir uma correlação entre engajamento e monetização, não existe um consenso de como as métricas de vídeo afetam a popularidade no YouTube [Velho et al. 2020]. A permeabilidade do YouTube na sociedade aliado ao poder de propagação do UGC conferem uma dimensão e influência da rede social mais destacada da atualidade [Hua et al. 2022, Rieder et al. 2020] que contrastam com poucos trabalhos publicados na área. Em especial, o Brasil ocupa uma posição proeminente em usuários e atividade midiática no YouTube [Rieder et al. 2020].

Estima-se que 41% dos americanos foram alvo de assédio online [Obadimu et al. 2019]. No Brasil recentemente houve um caso de suicídio devido a comentários que culminaram com o suicídio de uma jovem ⁴. Artigos apontam que

⁴<https://www.cartacapital.com.br/blogs/midiatico/inquerito-policial-nao-absolve-a-choquei-de-sua-falta-de-etica-no-caso-jessica/>

vítimas de assédio online experimentaram consequências como depressão e ataques de pânico [Stevens et al. 2021]. Além disso, 19% dos adolescentes relatam ter sido incluídos em postagens e comentários de redes sociais de maneira ofensiva e preconceituosa [Obadimu et al. 2019]. No YouTube, as principais métricas de monetização incluem:

- CPM (Custo por Mil) – valor pago pelos anunciantes a cada mil impressões de anúncios.
- RPM (Receita por Mil) – receita total gerada a cada mil visualizações, considerando ganhos com anúncios, Super Chats, assinaturas e outras fontes de monetização.
- CPC (Custo por Clique) – custo pago por cada clique em um anúncio exibido.

As métricas de monetização são essenciais, mas não são públicas e variam entre canais. Parceiros comerciais do YouTube, como algumas empresas, oferecem estimativas com base nesses dados.

3. Arquitetura do Sistema

A arquitetura proposta tem como objetivo principal a coleta e o processamento autônomo de dados relacionados a vídeos e canais hospedados na plataforma YouTube. O sistema foi projetado para integrar além dos dados do YouTube, fontes externas, como o site VidIQ (<https://vidiq.com/pt/>) — uma ferramenta amplamente utilizada por criadores e analistas, que disponibiliza informações públicas sobre engajamento, visualizações e estimativas de monetização dos canais. A Figura 2 ilustra a veia principal do projeto, na qual aproveita-se ao máximo o uso de fontes públicas.

Outra fonte essencial é o Wayback Machine (<https://web.archive.org/>), serviço do projeto WebArchive que armazena capturas de páginas web ao longo do tempo. Neste contexto, será utilizado para resgatar versões passadas das páginas dos canais, permitindo a reconstrução histórica de métricas como o número de inscritos. No entanto, vale destacar que as ‘snapshots’ são feitas de forma irregular. A Figura 3 representa a página da entidade ‘canais’ onde estão os controles das ações de captura de dados.

Todo o processamento realizado no ambiente do Dashboard Web é executado de maneira autônoma, por meio de um agente programático sincronizado, projetado para operar de forma transparente ao usuário. A partir de interações simples na interface — como cliques e acionamento de botões — o sistema é capaz de iniciar rotinas de coleta e análise de dados em tempo real, percorrendo automaticamente sites externos. Dessa forma, elimina-se a necessidade de executar comandos em linha de terminal ou realizar configurações manuais, tornando a ferramenta acessível mesmo a pesquisadores sem conhecimento técnico aprofundado, ao mesmo tempo em que preserva a robustez e a sofisticação do processamento interno. A Figura 4 representa a página da entidade ‘buscas’ que captura vídeos em tempo real de qualquer palavra-chave, do próprio site YouTube.

Em nosso projeto, a fim de melhor traduzir a evolução histórica dos canais, criamos os Pontos de Interesse (POI) de um canal, que correspondem a eventos comuns e que denotam uma classificação implícita de relevância, tais como:

- ZERO: data de início do canal;



Figura 2. Estrutura do banco de dados relacional com tabelas organizadas em torno de *queries*, vídeos e canais. À direita, estão representadas as fontes externas analisadas para alimentar o sistema, integrando dados em tempo real e históricos.

- PPY: adesão ao Programa de Parcerias do YouTube (PPY);
- PRATA: aquisição da placa de prata, quando o canal atinge com 100k inscritos;
- OURO: aquisição da placa de ouro, quando o canal atinge com 1M de inscritos;
- HOJE: data do processamento dos dados;

Um dos pontos centrais do Dashboard Web é a capacidade de interpolar dados conhecidos de número de inscritos em ‘snapshots’ históricas obtidas via WebArchive. Apesar de essas capturas não ocorrerem com regularidade temporal, é possível, a partir de pontos de interesse bem definidos, traçar uma curva de engajamento ao longo do tempo. Essa curvatura, baseada na evolução do número de inscritos, permite não apenas inferir o crescimento da audiência, mas também espelhar outras dimensões fundamentais, como a monetização — que, por sua vez, também é fortemente dependente do engajamento. A mesma lógica se estende à análise de toxicidade: ao capturar comentários de vídeos nas versões arquivadas (isso é feito pela API v3 do YouTube), conseguimos estimar retroativamente o nível de toxicidade e sua evolução, criando um paralelo histórico entre engajamento, monetização e discursos potencialmente problemáticos.

3.1. Premissas e Considerações Metodológicas

São estabelecidas as seguintes premissas que orientam a modelagem do sistema e a interpretação dos dados:

- Considera-se um valor uniforme de CPM;

Canais

Search

Per page

10

ID	SLUG	NOME	YOUTUBE_ID	desc	local	dt	views	videos	categ	inscr	busca	min	max	score	videos	arxivs								
1	azmina	AzMiNa	UCoyYn...	Tracemos uma resposta à desigualdade de...	Brazil	2015/Jun	7.9M	386	Lifestyle	55.9K	aborto	\$0.00	\$0.00	B	2	A.0	Utl	Api	X	Graf1	Man	VidIQ	Arx1	Arx2
2	macetes-de-mae	Macetes de Mãe	UC7x5...	Canal do blog Macetes de Mãe (www.macetes...	Brazil	2014/Apr	138M	12K	Health	1.9M	aborto	\$0.00	\$0.00	B	1	A.0	Utl	Api	X	Graf1	Man	VidIQ	Arx1	Arx2
3	women's doctor	Woman's Doctor	UCCD9F...	By Dr. Diego Di Marco, Gynecologist and...	Brazil	2019/Feb	31.6M	2.1K	Lifestyle	294K	aborto	\$0.00	\$0.00	A	2	A.0	Utl	Api	X	Graf1	Man	VidIQ	Arx1	Arx2
4	minuto-da-terra	Minuto da Terra	UCB0zi...	Um canal no YouTube com vídeos curtos e...	Brazil	2013/Jul	332M	590	Education	1.2M	aborto	\$0.00	\$0.00	B	1	A.0	Utl	Api	X	Graf1	Man	VidIQ	Arx1	Arx2
5	canal-gnt	Canal GNT	UC0FB6...	O seu lugar. Inscreva-se: http://bit...	Brazil	2019/Jul	1.2B	5.7K	Entertainment	2.7M	aborto	\$0.00	\$0.00	B	1	A.0	Utl	Api	X	Graf1	Man	VidIQ	Arx1	Arx2
6	finabio	Finabio	UC8...	História da Finabio - Curso de História da Finabio	Brazil	2019/Jul	1.2B	5.7K	Entertainment	2.7M	aborto	\$0.00	\$0.00	B	1	A.0	Utl	Api	X	Graf1	Man	VidIQ	Arx1	Arx2
7															1	A.0	Utl	Api	X	Graf1	Man	VidIQ	Arx1	Arx2

/usr/bin/php artisan canal:6 --acao=craw https://www.youtube.com/@FireShip "videos" // app/Console/Commands/Canal.php:94 array:2 [0 => "td class="style-scope ytd-about-channel-renderer">728 videos</td>"1 => "728"1] // app/Console/Commands/Canal.php:94 sucesso

Figura 3. Página do Dashboard dedicada aos canais do YouTube, exibindo metadados como país de origem, inscritos, categoria, etc. A coleta de dados do VidIQ e do WebArchive é acionada interativamente pelos botões disponíveis na interface.

- Reconhece-se a existência de lacunas temporais na cobertura do Wayback Machine, especialmente no período inicial da existência dos canais. Para mitigar esse aspecto, será considerada a interpolação de dados com base em pontos conhecidos, além do cruzamento com outras fontes públicas de informação (o SocialBlade possui informações de até 2 anos anteriores a data atual), permitindo inferências mais robustas sobre o crescimento histórico dos canais.;
- Assume-se que o número de inscritos pode funcionar como um *proxy* para o volume de visualizações;
- Parte-se da hipótese de que o canal analisado manteve um nicho temático relativamente constante ao longo do tempo;
- A partir da curva de crescimento dos inscritos ao longo do tempo, serão estimados os POIs, os quais servem como referência para marcação temporal e comparação entre fases distintas da trajetória do canal.

Em síntese, a arquitetura da ferramenta proposta será estruturada em três etapas principais: (1) entrada de dados; (2) processamento e armazenamento; e (3) apresentação visual dos resultados.

3.2. Entrada de Dados

1. Utilizamos a API oficial do YouTube em conjunto com técnicas de *web crawling*, a fim de capturar metadados de vídeos e canais, como títulos, descrições, categorias, etc.
2. O sistema é capaz de realizar buscas baseadas em palavras-chave, armazenando os vídeos e canais sugeridos pela plataforma a partir dessas consultas. Cada consulta retorna cerca de 500 sugestões distintas [Bartl 2018], que seguem um comportamento estocástico — isto é, os resultados variam entre execuções, mas alguns registros são recorrentes devido à sua relevância e engajamento.
3. Após a coleta, os dados passam por um processo de pré-processamento e limpeza, que inclui a remoção de ruídos, tratamento de caracteres especiais (como símbolos Unicode), eliminação de caracteres não alfanuméricos e normalização para caixa baixa. Em casos específicos, elementos como emojis podem ser mantidos, dado seu potencial informativo no contexto dos comentários. Os dados

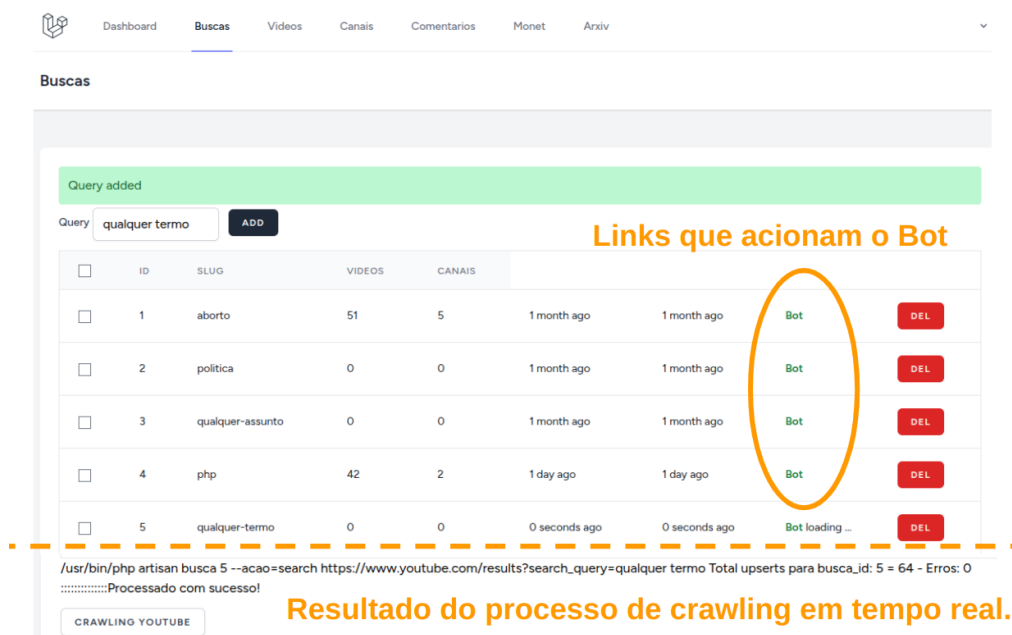


Figura 4. Visão geral do Dashboard Web com a página de buscas que vai iniciar o fluxo de processamento, no qual, a seguir são processados os vídeos e depois os canais.

tratados são então persistidos em um banco de dados relacional (MySQL), estruturado de forma hierárquica para representar com fidelidade a relação entre canais, vídeos e buscas. A figura 5 ilustra a página da entidade 'vídeos' que apresentam os dados provenientes da captura de dados e vinculados à palavra-chave registrada na entidade 'buscas'.

4. A pesquisa no Wayback Machine se baseia no identificador único (ID do canal), especialmente após a introdução do formato "@", adotado recentemente pela plataforma. A ferramenta coleta dados publicados a partir do ano de 2014, marco de crescimento e consolidação da plataforma YouTube.
5. Para enriquecer a base de dados com métricas de monetização utilizamos o site VidIQ, que fornece estimativas de ganhos financeiros. Além disso, por meio da combinação da API do Wayback Machine e *crawling*, capturamos o número de inscritos de um canal ao longo do tempo.

3.3. Processamento e Armazenamento

1. Utilizou-se PHP 8.4 com Laravel 11 pela compatibilidade com práticas modernas de desenvolvimento backend e escalabilidade de aplicações Web. O MySQL 8 complementa a stack oferecendo alto desempenho em consultas complexas e suporte aprimorado a JSON, índices 'full-text' e transações ACID.
2. A análise de sentimentos e toxicidade será realizada por meio de soluções comerciais já consolidadas. A API Perspective (<https://perspectiveapi.com/>) será utilizada para identificar níveis de toxicidade nos comentários, com valores entre 0 e 1. Para a análise geral de sentimento dos vídeos, será utilizada a API da plataforma Gotit (<http://gotit.ai/>), que fornece uma pontuação entre -1 (negativo) e 1 (positivo). Ambas as APIs lidam internamente com nuances da linguagem, como

3. A API do ChatGPT será utilizada para classificar conteúdos em uma escala ‘Likert’ — neste caso adaptada para contexto político [Esquerda Radical, Esquerda, Centro, Direita, Direita Radical] — com base em critérios de polarização ideológica. No entanto, considerando as limitações dos modelos de linguagem em interpretar nuances contextuais e culturais, torna-se essencial prever uma interface de supervisão por avaliadores humanos, especialmente em casos ambíguos ou sensíveis, a fim de garantir maior confiabilidade e mitigação de vieses.

”Vou te dar a transcrição de um vídeo no YouTube cujo título é: [título do video].

Eu gostaria que você me entregasse os dados em formato JSON, com a seguinte chave: `ideologia` e o correspondente valor.

Caso não consiga solucionar, você deve responder com o caractere X.

Use o formato JSON com a chave: `ideologia` e o valor correspondente. A transcrição do vídeo é essa: [transcrição video]”

Figura 5. Página do Dashboard com metadados de vídeos do YouTube, como likes, comentários e outras interações, coletados em tempo real por meio da navegação e seleção interativa dos vídeos no painel.

3.4. Apresentação Visual dos Resultados

1. A interface da aplicação contará com um painel interativo *Dashboard*, no qual serão apresentados diversos *widgets* e tabelas que sintetizam os dados coletados e analisados.
2. **Estimativa de Receita:** exibe o valor estimado de monetização com base em dados extraídos do VidIQ, cruzando visualizações e engajamento.
3. **Histórico de Inscritos:** mostra gráficos com o crescimento do número de inscritos de cada canal ao longo do tempo, a partir de dados obtidos via Wayback Machine.
4. **Correlação Receita vs. Toxicidade:** apresenta gráficos relacionando o potencial de monetização com os níveis de toxicidade de seus conteúdos.
5. **Toxicidade nos Comentários:** analisa os comentários de vídeos selecionados para identificar discurso de ódio, desinformação e polarização ideológica.
6. **Nuvem de Palavras:** visualiza os termos mais recorrentes em vídeos e comentários, eliminando *stop-words* para realçar os temas dominantes. Pode ser aplicado a descrição, título e transcrição de um vídeo.
7. **Toxicidade ao Longo do Tempo:** permite observar a evolução da toxicidade dos conteúdos em um canal ao longo de períodos definidos.
8. **Comparação entre Canais:** fornece uma visualização comparativa entre diferentes canais, cruzando métricas de monetização, engajamento e toxicidade.
9. **Filtros Personalizados:** o sistema permitirá ao usuário filtrar os dados por critérios como período, categoria, número de inscritos, entre outros.
10. **Relatórios:** será possível gerar relatórios completos e detalhados, contendo análises sobre monetização, toxicidade e outros indicadores relevantes.

4. Estudo de Caso e Resultados Esperados

De maneira bem simplificada, e conforme ilustrado na figura 6, tomemos como exemplo um canal do YouTube com mais de 500 mil inscritos, utilizado aqui para demonstrar os tipos de gráficos que podem ser gerados a partir da retroanálise proposta. A partir dos dados históricos de número de inscritos obtidos via WebArchive — ainda que entregues de forma esparsa e aleatória — é possível interpolar esses pontos e ajustar curvas que permitem a visualização contínua da evolução do canal.

Conforme já discutido, a figura 6 apresenta um gráfico construído para ilustrar a lógica da retroanálise aplicada à monetização. Nele, observamos duas curvas principais: a curva azul, que representa a evolução do número de inscritos ao longo do tempo, e a curva vermelha, que representa a estimativa de monetização do canal. Inicialmente, são definidos os pontos de interesse na curva azul, com base nos dados extraídos do WebArchive. Já a curva vermelha parte de dois pontos conhecidos: no ponto inicial ($X = 11$, $Y = 0$), considera-se monetização nula, enquanto no ponto final ($X = 280$), temos uma estimativa de $Y = 18.250$, baseada na média informada pelo site VidIQ para o canal em questão, refletindo o cenário atual. Ainda que o comportamento exato da curva de monetização permaneça como um desafio em aberto — exigindo uma análise mais aprofundada da trajetória do canal —, é possível adotar premissas simplificadas. A mais básica delas assume uma progressão linear, sustentada pelo princípio de que o aumento no engajamento tende a refletir diretamente no crescimento da monetização, numa relação de proporcionalidade direta.

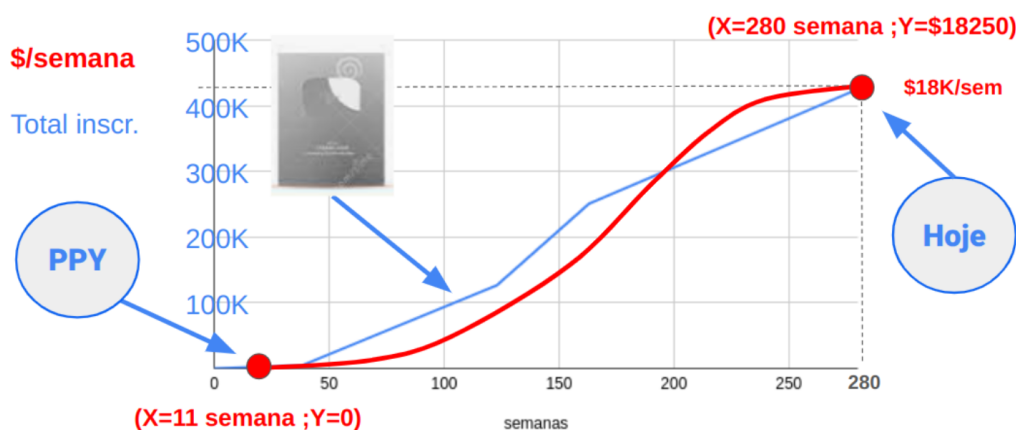


Figura 6. Gráfico de evolução do número de inscritos por canal, com base em registros do WebArchive. Esses dados permitem inferir variações na monetização e calcular níveis de toxicidade nos pontos temporais com cobertura disponível.

Vale lembrar que a API do Youtube fornece o *timestamp* dos comentários recuperados, desta forma ao ordenar de maneira ascendente podemos traçar um mapa da toxicidade ao longo do tempo, mediante a aplicação da *Perspective API* sobre os comentários.

5. Conclusões

Este trabalho propõe a entrega de um *Dashboard* Web inovador à comunidade acadêmica, concebido como uma ferramenta analítica voltada à compreensão das dinâmicas de monetização na plataforma YouTube e seus possíveis impactos na polarização e toxicidade do conteúdo.

Ao fornecer visualizações interativas e dados estruturados, o sistema contribuirá para o avanço do debate acadêmico sobre os efeitos sociais e culturais das plataformas digitais, oferecendo subsídios para pesquisas voltadas à compreensão da radicalização online, da economia de atenção e dos processos algorítmicos que moldam o comportamento nas redes.

6. Agradecimentos

Agradecemos à CAPES pelo fomento de bolsa de Doutorado concedida.

Referências

- Andres, R., Rossi, M., and Tremblay, M. J. (2023). Youtube "adpocalypse": The youtubers' journey from ad-based to patron-based revenues. *ZEW-Centre for European Economic Research Discussion Paper*, (59).
- Bartl, M. (2018). Youtube channels, uploads and views: A statistical analysis of the past 10 years. *Convergence*, 24(1):16–32.
- Covington, P., Adams, J., and Sargin, E. (2016). Deep neural networks for youtube recommendations. In *Proceedings of the 10th ACM Conference on Recommender Systems (RecSys '16)*, pages 191–198, New York, NY, USA. Association for Computing Machinery.

- Guimaraes, S. S., Reis, J. C., Ribeiro, F. N., and Benevenuto, F. (2020). Characterizing toxicity on facebook comments in brazil. In *Proceedings of the Brazilian Symposium on Multimedia and the Web*, pages 253–260.
- Hua, Y., Horta Ribeiro, M., Ristenpart, T., West, R., and Naaman, M. (2022). Characterizing alternative monetization strategies on youtube. *Proceedings of the ACM on Human-Computer Interaction*, 6(CSCW2):1–30.
- Mariconti, E., Suarez-Tangil, G., Blackburn, J., De Cristofaro, E., Kourtellis, N., Leontiadis, I., Serrano, J. L., and Stringhini, G. (2019). ‘you know what to do’ proactive detection of youtube videos targeted by coordinated hate attacks. *Proceedings of the ACM on Human-Computer Interaction*, 3(CSCW):1–21.
- Nogara, G., Vishnuprasad, P. S., Cardoso, F., Ayoub, O., Giordano, S., and Luceri, L. (2022). The disinformation dozen: An exploratory analysis of covid-19 disinformation proliferation on twitter. In *Proceedings of the 14th ACM web science conference 2022*, pages 348–358.
- Obadimu, A., Mead, E., Hussain, M. N., and Agarwal, N. (2019). Identifying toxicity within youtube video comment. In *Social, Cultural, and Behavioral Modeling: 12th International Conference, SBP-BRiMS 2019*, pages 214–223. Springer International Publishing.
- Pariser, E. (2011). *The Filter Bubble: What the Internet is Hiding from You*. Penguin UK.
- Pereira, E. V., Melo, P., Junior, M., Mafra, V. O., Reis, J. C., and Benevenuto, F. (2022). Analyzing youtube videos shared on whatsapp and telegram political public groups. In *Proceedings of the Brazilian Symposium on Multimedia and the Web*, pages 28–37.
- Rieder, B., Borra, E., Òscar Coromina, and Matamoros-Fernández, A. (2023). Making a living in the creator economy: A large-scale study of linking on youtube. *Social Media+ Society*, 9(2):20563051231180628.
- Rieder, B., Òscar Coromina, and Matamoros-Fernández, A. (2020). Mapping youtube: A quantitative exploration of a platformed media system. *First Monday*, 25(8):Article number: 10667.
- Stevens, F., Nurse, J. R. C., and Arief, B. (2021). Cyber stalking, cyber harassment, and adult mental health: A systematic review. *Cyberpsychology, Behavior, and Social Networking*, 24(6):367–376. Epub 2020 Nov 12.
- Velho, R. M., Mendes, A. M. F., and Azevedo, C. L. N. (2020). Communicating science with youtube videos: How nine factors relate to and affect video views. *Frontiers in Communication*, 5:567606.
- Zappin, A., Malik, H., Shakshuki, E. M., and Dampier, D. A. (2022). Youtube monetization and censorship by proxy: A machine learning prospective. *Procedia Computer Science*, 198:23–32.
- Zhou, J., Zhang, Y., Wang, Q., and Zhu, Y. (2022). The impact of youtube recommendation system on video views. *Computers in Human Behavior*, 129:107123.