A Percepção Pública da Inteligência Artificial: Uma Análise Sociotécnica de Comentários no YouTube

Igor Joaquim Costa, Jussara Almeida
Departamento de Ciência da Computação
Universidade Federal de Minas Gerais (UFMG)
Belo Horizonte, Brasil
{igor.joaquim, jussara}@dcc.ufmg.br

***Resumo*—O rápido avanço da Inteligência Artificial (IA), impulsionado pela popularização de Modelos de Linguagem de Grande Escala (LLMs), tem reconfigurado profundamente a relação entre sociedade e tecnologia, consolidando novos imaginários sociotécnicos. Compreender a percepção pública sobre essas transformações é imperativo para orientar a governança algorítmica e mitigar riscos existenciais e regulatórios. Contudo, os métodos tradicionais de pesquisa de opinião falham em capturar a natureza dinâmica, auto-organizada e contextualizada das discussões orgânicas em plataformas digitais. Este trabalho investiga a percepção pública e a recepção de narrativas sobre IA por meio de uma análise sociotécnica em larga escala de comentários na plataforma YouTube. A partir de um corpus multi-idioma de mais de 520 mil comentários (354.534 em inglês e 168.518 em português) vinculados a vídeos previamente categorizados segundo a Teoria de Valores Humanos de Schwartz, implementou-se um pipeline de Processamento de Linguagem Natural (PLN) e Ciência Social Computacional (CSS) utilizando LLMs via framework *vLLM* para execução distribuída de tarefas de filtragem de spams e caracterização do engajamento e expressividade do público.**

A análise estatística não-paramétrica (Mann-Whitney U) e a modelagem psicolinguística baseada em dicionários de radicais revelaram divergências transculturais significativas entre os públicos do Brasil (Sul Global / *Compute South*) e dos Estados Unidos (Norte Global / *Compute North*). Enquanto o público brasileiro manifesta um discurso significativamente mais comunitário e interpessoal, caracterizado por índices elevados de Processos Sociais e Preocupações Pessoais, o público norte-americano prioriza discursos orientados a Motivações instrumentais (conquistas e metas corporativas) e Linguagem Informal. Adicionalmente, a correlação de Spearman revelou que debates ativos de alto esforço cognitivo são estimulados por discussões associadas a Universalismo e Segurança, enquanto o consumo passivo (visualizações) é impulsionado por Estimulação e Hedonismo. Estes resultados demonstram a utilidade das seções de comentários como um espelho sociotécnico do debate público e ressaltam a necessidade de se considerar as assimetrias regionais e infraestruturais nas políticas de desenvolvimento e governança da inteligência artificial.

Palavras-chave: Inteligência Artificial. Percepção Pública. YouTube. Ciência Social Computacional. Processamento de Linguagem Natural. Valores Humanos de Schwartz.

***Index Terms*—Inteligência Artificial, YouTube, Análise Sociotécnica, Valores de Schwartz, Psicolinguística, Percepção Pública.**

I. Introdução

A. Caracterização do Problema

O rápido avanço da Inteligência Artificial (IA), impulsionado pela consolidação de arquiteturas baseadas em *Transformers* e Modelos de Linguagem de Grande Escala (LLMs), transcendeu as fronteiras dos laboratórios acadêmicos e industriais para se integrar de forma capilar ao cotidiano das sociedades contemporâneas. A incorporação célere de sistemas geradores de texto, código e imagens em setores críticos como educação, saúde, jornalismo e mercado corporativo configura um processo de transição sociotécnica acelerado. Se, por um lado, esse fenômeno fomenta expectativas de ganhos inéditos de produtividade e aceleração da inovação, por outro, desperta intensas preocupações éticas, incluindo riscos de desemprego tecnológico estrutural, amplificação de preconceitos históricos em dados de treinamento, erosão da privacidade e desafios à integridade informacional.

Nesse cenário de transição, a modelagem e a compreensão da **percepção pública** acerca da inteligência artificial constituem um imperativo científico e regulatório. A forma como a sociedade civil absorve, negocia ou resiste a essas inovações determina a aceitabilidade dos sistemas inteligentes, influencia a formulação de regulamentações estatais e molda os rumos da governança tecnológica. Historicamente, a aferição da opinião pública sobre ciência e tecnologia tem se amparado em abordagens metodológicas tradicionais, tais como questionários de amostragem estática e entrevistas estruturadas (e.g., levantamentos do *Pew Research Center*). Embora metodologicamente consolidados, tais instrumentos apresentam limitações epistemológicas severas:

1) **Esticidade e Artificialidade das Respostas:** Os questionários tendem a induzir respostas ao forçar o respondente a escolher entre opções pré-definidas em cenários abstratos, capturando opiniões efêmeras e descontextualizadas em vez de discursos gerados organicamente no cotidiano de consumo da informação.
2) **Ignorância da Dinâmica Algorítmica:** Desconsideram o papel mediador dos sistemas algorítmicos de

recomendação que modulam a visibilidade e direcionam quais discursos chegam ao cidadão comum.

3) **Viés Epistêmico WEIRD:** A esmagadora maioria das pesquisas e frameworks regulatórios é concebida a partir de populações ocidentais, escolarizadas, industrializadas, ricas e democráticas (*Western, Educated, Industrialized, Rich, Democratic*). Esse viés universaliza a percepção do Norte Global e desconsidera as realidades materiais, econômicas e infraestruturais do Sul Global.

Para preencher essa lacuna, a Ciência Social Computacional (CSS) propõe a análise de rastros digitais como *proxy* para a percepção pública orgânica. Plataformas digitais, e em particular o YouTube, operam como a nova esfera pública digital de Habermas. O YouTube constitui o maior ecossistema de compartilhamento e consumo de conteúdo de vídeo do mundo, atuando como um vetor central de divulgação científica, entretenimento e engajamento sociopolítico. Suas seções de comentários constituem um repositório textual contínuo, não indutivo, altamente ruidoso e abundante das reações do público leigo diante de narrativas tecnológicas expostas nos vídeos.

Sob a perspectiva sociotécnica, o ecossistema do YouTube pode ser modelado como um sistema de interação tripartite entre:

1) A **Oferta Discursiva** (Criador, C), que enquadra a tecnologia sob a influência de seus próprios valores humanos e objetivos de engajamento, projetando um imaginário sociotécnico específico.
2) A **Mediação Algorítmica** (Algoritmo, A), que atua como filtro e distribuidor de visibilidade baseado em métricas de retenção e interação.
3) A **Demanda Discursiva** (Audiência, R), que reage produzindo comentários que aceitam, negociam ou contestam o enquadramento original.

A percepção pública não é homogênea, mas sim condicionada pelas assimetrias na distribuição global do poder computacional. Geopoliticamente, essa disparidade é formalizada pela divisão entre o **Compute North** (Norte Computacional) — detentor do monopólio da infraestrutura de supercomputação (GPUs, data centers) e controle sobre os dados e pesos dos modelos de IA — e o **Compute South** (Sul Computacional) — posicionado predominantemente como consumidor de modelos de fundação importados ou provedor de mão de obra de baixo custo para anotação de dados. O viés cognitivo WEIRD inserido nos modelos do *Compute North* acarreta uma distribuição de probabilidade de treinamento $P_\text{WEIRD}(X)$ que difere substancialmente da distribuição cultural e sociopolítica local do Sul Global $P_\text{South}(X)$. A análise de comentários no YouTube permite mapear essa divergência semântico-cultural, contrastando as reações de públicos situados em polos opostos dessa cadeia de poder.

B. Motivação

O processo de recepção pública de novas tecnologias não ocorre em um vácuo; ele é ativamente mediado pelas narrativas produzidas pelos formadores de opinião. No ecossistema do YouTube, os criadores de conteúdo atuam como importantes tradutores e mediadores sociotécnicos, empacotando conceitos de IA complexos e apresentando-os sob determinados enquadramentos (*framings*). A forma como o criador de conteúdo enquadra a tecnologia atua como o estímulo que modela o debate público.

A primeira fase deste projeto investigou o lado da **oferta** desse discurso. Por meio do mapeamento de milhares de transcrições de vídeos no Brasil e nos Estados Unidos, identificou-se uma divergência sociotécnica nítida na produção de conteúdo:

- O discurso norte-americano foca predominantemente em eficiência produtiva, monetização e competitividade corporativa (*Compute North*).
- O discurso brasileiro confere forte ênfase à adaptação social, preocupações trabalhistas, impactos educacionais e implicações cotidianas (*Compute South*).

A motivação para este trabalho surge da necessidade crítica de analisar a outra metade desse fenômeno: a **demanda** ou **recepção**. Compreender o discurso dos criadores é insuficiente se não investigarmos como a audiência consome, aceita, contesta ou ressignifica essas narrativas. A seção de comentários funciona como um espelho sociotécnico no qual as reações do público podem ser contrapostas ao conteúdo oferecido.

A realização desta pesquisa é motivada por três fatores principais:

1) **Modelagem Matemática e NLP para Textos Ruidosos:** A linguagem dos comentários em mídias digitais é marcada por alta informalidade, brevidade, uso de gírias, emojis, ironia e spams. Desenvolver e validar pipelines computacionais robustos baseados em LLMs que consigam filtrar esse ruído e extrair o posicionamento (*stance*) do público de forma escalável é um desafio metodológico aberto na área de PLN aplicado à Computação Social.
2) **Assimetrias Culturais e de Desenvolvimento:** Há escassez de estudos comparativos transculturais de larga escala que avaliem como os mesmos estímulos tecnológicos em IA são recebidos por públicos do Norte Global (EUA) e do Sul Global (Brasil), considerando as assimetrias na distribuição de poder computacional e infraestrutura.
3) **Impacto na Governança e Ética de IA:** Entender se o engajamento do público é motivado por fatores de ganho econômico ou por preocupações éticas e de segurança é crucial para formuladores de políticas públicas e desenvolvedores, garantindo sistemas alinhados aos valores humanos de diferentes sociedades.

C. Objetivos do Trabalho

1) Objetivo Geral: Mapear e analisar de forma comparativa a percepção pública sobre a Inteligência Artificial no Brasil e nos Estados Unidos por meio da análise sociotécnica em larga escala de comentários no YouTube, contrapondo as reações da audiência aos discursos dos criadores de conteúdo e investigando as variações culturais implícitas.

2) Objetivos Específicos: Para alcançar o objetivo geral, as seguintes metas específicas foram estabelecidas:

1) **Consolidação e Curadoria do Corpus:** Consolidar e pré-processar um corpus representativo e anonimizado de comentários do YouTube (comentários principais e respostas) correspondentes aos vídeos analisados na etapa anterior, totalizando mais de 520 mil registros em inglês e português.
2) **Pipeline de PLN Avançado:** Desenvolver, otimizar e documentar um pipeline computacional de alta eficiência utilizando o framework *vLLM* e modelos de linguagem de grande escala (LLMs), adaptado especificamente para a limpeza, filtragem de spam e extração de métricas de escrita de textos curtos e informais de redes sociais.
3) **Caracterização Descritiva dos Comentários:** Desenvolver e aplicar heurísticas para extrair o nível de esforço de escrita e os marcadores de expressividade (emojis, exclamações e perguntas) nos comentários.
4) **Análise Psicolinguística Transcultural:** Mapear e comparar estatisticamente (via teste de Mann-Whitney U) os perfis linguísticos e categorias psicológicas do público brasileiro e norte-americano, utilizando dicionários de radicais (*stems*) nativos inspirados na metodologia LIWC (*Linguistic Inquiry and Word Count*).
5) **Estudo de Engajamento e Valores Humanos:** Investigar a correlação de Spearman entre os perfis de Valores Humanos de Schwartz (identificados nas transcrições na fase anterior) e as métricas de engajamento do público, avaliando quais valores motivam a interação ativa (comentar) e a passiva (visualizar) na plataforma.

D. Estrutura do Trabalho

Este relatório de Conclusão de Curso está organizado em cinco capítulos estruturados da seguinte forma:

- **Capítulo 2 – Referencial Teórico:** Revisa a literatura sobre a percepção pública da IA sob a ótica de assimetrias globais (psicologia WEIRD, *Compute North* vs. *Compute South*) e imaginários sociotécnicos; detalha a modelagem da mediação de conteúdo e culturas de ranqueamento no YouTube; e introduz a fundamentação da análise psicolinguística baseada em léxicos estruturados.
- **Capítulo 3 – Metodologia:** Detalha o pipeline computacional concebido, a estratégia de triagem baseada em LLMs e classificação de idioma via FastText, os procedimentos éticos e de anonimização adotados, e os indicadores tipográficos e de expressividade para caracterização do nível de esforço de escrita da audiência.
- **Capítulo 4 – Resultados e Discussão:** Apresenta e discute os achados quantitativos e qualitativos, incluindo as estatísticas descritivas dos comentários, a correlação entre valores e engajamento, as redes de coocorrência de valores e a comparação psicolinguística contrastiva das reações do público brasileiro e norte-americano.
- **Capítulo 5 – Considerações Finais:** Sintetiza as conclusões do trabalho, elucida as limitações metodológicas identificadas e aponta direções para investigações futuras no campo da Computação Social.

E. Declaração de Transparência sobre o Uso de IA Generativa

Em conformidade com as diretrizes do Trabalho de Conclusão de Curso do Departamento de Ciência da Computação (DCC/UFMG) relativas à conduta ética e ao uso responsável de tecnologias auxiliares, declara-se que ferramentas de inteligência artificial generativa baseadas em Modelos de Linguagem de Grande Escala foram empregadas exclusivamente para suporte na estruturação textual, revisão gramatical e ortográfica do manuscrito, bem como no auxílio à tradução técnica dos resumos acadêmicos. Todo o arcabouço conceitual, formulação de hipóteses, projeto do pipeline de processamento, análise estatística e interpretação dos dados experimentais contidos nesta monografia constituem produção intelectual original e de inteira responsabilidade do autor.

II. Referencial Teórico

Este capítulo apresenta o embasamento teórico e conceitual que sustenta esta pesquisa, localizando-se na interseção entre os Estudos Sociotécnicos de Mídia e a Ciência Social Computacional (CSS). O objetivo é prover os fundamentos teóricos para analisar a recepção pública da Inteligência Artificial (IA) em comentários do YouTube, comparando as perspectivas do Brasil (Sul Global) e dos Estados Unidos (Norte Global).

O capítulo está estruturado em três seções principais:

1) **Percepção Pública da IA e Assimetrias Globais:** Aborda a variabilidade cultural na recepção da IA sob a ótica da psicologia WEIRD e das divisões geopolíticas entre *Compute North* e *Compute South*.
2) **Enquadramento, Mediação e Dinâmicas de Recepção no YouTube:** Modela as relações entre produtores de conteúdo, modulação algorítmica e a recepção pública na seção de comentários.
3) **Análise Psicolinguística Baseada em Léxicos:** Fundamenta a extração de categorias psicolinguísticas para mensurar processos cognitivos e afetivos no discurso online.

A. Percepção Pública da IA e Assimetrias Globais

Estudos transculturais revelam divergências marcantes na percepção pública da IA de acordo com o nível de desenvolvimento econômico. Enquanto nações desenvolvidas (Norte Global) tendem a manifestar sentimentos de preocupação e ceticismo, populações em nações em desenvolvimento (Sul Global) apresentam maior otimismo e entusiasmo associados à utilidade prática da tecnologia. Sob a ótica da psicologia WEIRD (populações ocidentais, escolarizadas, industrializadas, ricas e democráticas), a recepção da tecnologia é mediada por altas demandas de governança e privacidade. Em contrapartida, no Sul Global, a IA é frequentemente enquadrada como uma oportunidade de superação de lacunas infraestruturais e aceleração educacional.

Essas diferenças atitudinais refletem a assimetria na distribuição global do poder computacional, dividida entre o **Compute North** — detentor do monopólio de supercomputadores, data centers e controle sobre modelos de fundação — e o **Compute South** — posicionado como consumidor de ferramentas importadas e provedor de mão de obra para rotulação de dados. Essa disparidade material gera dependência epistêmica, pois os modelos de fundação incorporam distribuições valorativas típicas de dados WEIRD que se chocam com as dinâmicas socioculturais do Sul Global. O mapeamento de reações em seções de comentários de redes sociais permite evidenciar empiricamente esse desalinhamento.

B. Enquadramento (Framing), Mediação e Dinâmicas de Recepção no YouTube

No ecossistema de mídias digitais, os criadores de conteúdo atuam como tradutores sociotécnicos que guiam a opinião pública ao promover enquadramentos (*framings*) específicos das tecnologias. Contudo, há um descompasso notório entre a oferta discursiva dos produtores e a demanda da audiência: enquanto criadores tendem a enfatizar aspectos normativos, técnicos e de mercado, o público leigo reage com base em preocupações cotidianas e temores práticos, tais como automação trabalhista e privacidade.

Essa dinâmica é mediada pelas culturas de ranqueamento (*ranking cultures*), que correspondem à interação contínua entre o criador (oferta discursiva), a recomendação algorítmica (que otimiza a visibilidade baseada em engajamento) e o receptor (que expressa reações na seção de comentários). A seção de comentários do YouTube funciona como um espaço de contestação sociotécnica, permitindo que a audiência adote passivamente o enquadramento do criador ou renegocie ativamente os termos do debate, fornecendo uma base rica de rastros digitais para a compreensão da percepção pública real sobre a IA.

C. Análise Psicolinguística Baseada em Léxicos (LIWC)

Para capturar de forma quantitativa os estados mentais, emoções e processos cognitivos contidos nas reações do público, a literatura de Ciência Social Computacional emprega análises baseadas em dicionários lexicais estruturados. O método central fundamenta-se no framework do software *LIWC* (*Linguistic Inquiry and Word Count*), que mapeia termos e radicais lexicais (*stems*) nativos a categorias psicológicas pré-definidas (como processos afetivos, sociais, biológicos, motivações e preocupações). A relevância de cada categoria é computada como a frequência relativa de termos correspondentes no texto do comentário, permitindo a quantificação sistemática de nuances avançadas no discurso online.

III. Metodologia

Este capítulo descreve a metodologia desenvolvida para analisar a percepção pública e a recepção das narrativas sobre Inteligência Artificial (IA) em comentários de plataformas de compartilhamento de vídeo. Adota-se uma abordagem quantitativa, empírica e computacional fundamentada nos princípios da Ciência Social Computacional (*Computational Social Science* - CSS), combinando técnicas de Processamento de Linguagem Natural (PLN), aprendizado de máquina supervisionado via modelos de linguagem autoregressivos e baseados em *Transformers*, e inferência estatística não-paramétrica. O objetivo é mapear e comparar os discursos e as reações do público em dois corpora geograficamente e linguisticamente distintos: usuários do Brasil (em português) e dos Estados Unidos (em inglês).

O fluxo de processamento de dados é estruturado em cinco macro-etapas fundamentais:

1) **Coleta de Metadados e Transcrições:** Extração dos dados primários dos vídeos do YouTube (metadados e transcrições textuais) para compor a base de análise da oferta discursiva.
2) **Triagem Temática e de Idioma:** Aplicação do modelo Llama-3-8B-Instruct nos títulos dos vídeos para triagem de relevância à IA e do classificador FastText para filtragem dos idiomas português e inglês.
3) **Extração e Pré-processamento de Comentários:** Coleta em larga escala das seções de comentários vinculadas aos vídeos triados, seguida de etapas de limpeza, remoção de spams e anonimização irreversível dos dados para conformidade ética.
4) **Extração de Valores e Atributos Psicolinguísticos:** Processamento das transcrições via DeBERTa-v3 (com técnica de janela deslizante) para inferência dos Valores Humanos de Schwartz, alinhamento geométrico de coordenadas de texto para correspondência cross-cultural e contagem de radicais psicolinguísticos (LIWC) em inglês e português.
5) **Mensuração de Esforço e Análise Estatística Integrada:** Caracterização do nível de esforço cognitivo de escrita da audiência (comprimento e expressividade), seguida de testes de hipóteses estatísticas de Mann-Whitney U, cálculo de coeficientes de correlação de Spearman e modelagem temática (BERTopic) para contrapor as dinâmicas de oferta (criadores) e demanda (audiência).

A. Coleta e Triagem de Vídeos

A base primária de dados é composta por metadados de vídeos do YouTube e suas respectivas transcrições textuais. A seleção inicial baseou-se em uma amostra de canais selecionados de forma estratégica para representar a diversidade de enquadramentos (*framing*) ideológicos, técnicos e midiáticos. Os canais foram categorizados em quatro domínios principais:

1) **Canais de Tecnologia:** Conteúdos focados em programação, desenvolvimento de ferramentas e novidades técnicas de engenharia.
2) **Divulgação Científica:** Canais orientados a explicar fundamentos matemáticos e conceituais subjacentes à computação e à IA.

3) **Podcasts:** Formatos de entrevistas longas e debates semiestruturados de cunho filosófico, econômico e cultural.
4) **Mídia Tradicional:** Veículos informativos corporativos de grande porte cobrindo aspectos regulatórios, econômicos e geopolíticos.

A extração foi efetuada por meio da *YouTube Data API v3*, utilizando os endpoints `search().list` e `videos().list` para recuperar metadados temporais (data de upload), estatísticas de engajamento (contagem de visualizações, curtidas, comentários) e os identificadores únicos (`video\_id`).

1) Triagem de Vídeos baseada em Títulos e Classificação de Idioma: Dado o grande volume de publicações dos canais selecionados, muitos vídeos não abordavam diretamente a Inteligência Artificial. Para construir um corpus altamente preciso, desenvolveu-se um pipeline de triagem estruturado em duas etapas principais:

1) **Classificação Temática via Llama-3-8B-Instruct:** O título do vídeo (T_V) é submetido ao modelo de linguagem de grande escala **Llama-3-8B-Instruct** ($\mathcal{M}$_8B). O prompt emprega técnicas de aprendizado em contexto com poucos exemplos (*few-shot prompting*) e indução de raciocínio lógico em cadeia (*Chain-of-Thought* - CoT), instruindo o modelo a gerar um raciocínio lógico abreviado antes de produzir a classificação final em formato estruturado.

A estrutura padrão do prompt de triagem é expressa no bloco abaixo:

```
[System Prompt]
Você é um classificador neural altamente
especializado e rigoroso. Sua tarefa é
avaliar se o título de um vídeo aborda
diretamente o tema da Inteligência
Artificial (IA), Aprendizado de Máquina,
Deep Learning, Processamento de Linguagem
Natural, Visão Computacional ou
tecnologias de IA Generativa.

[Few-Shot Examples]
Exemplo 1:
Título: "Como funciona o GPT-4: Entenda
a arquitetura de Transformers"
Raciocínio: O título menciona GPT-4
e Transformers, que são modelos e
arquiteturas de IA de última geração.
Saída: {"is_ai_related": true,
        "confidence": "Alta"}

Exemplo 2:
Título: "A crise dos chips: Como a
geopolítica afeta os semicondutores"
Raciocínio: O foco do título é a
crise econômica de semicondutores
e geopolítica de hardware, não a
tecnologia de IA em si.
Saída: {"is_ai_related": false,
        "confidence": "Alta"}

Exemplo 3:
Título: "O futuro da automação
inteligente no trabalho moderno"
Raciocínio: O termo "automação
inteligente" é semanticamente ambíguo,
podendo referir-se tanto a regras
clássicas quanto a IA. O título não
fornece detalhes suficientes.
Saída: {"is_ai_related": true,
        "confidence": "Baixa"}

[Input]
Título: "{title}"
Responda no formato JSON:
{"is_ai_related": <boolean>,
 "confidence": "Alta"|"Baixa",
 "reasoning": "<str>"}
```

A inferência temática é modelada como:

$$y_{\text{AI}}(V) = \mathcal{M}_{\text{8B}}\left(\text{Prompt}_{\text{stage1}}(T_V)\right)$$

Onde $y_\text{AI}(V) \in \{0, 1\}$ indica a relevância temática do vídeo.

1) **Identificação e Filtragem de Idioma via FastText:** Após a triagem temática, aplicou-se o classificador de idiomas **FastText** (desenvolvido pelo Facebook AI Research) sobre a transcrição e metadados do vídeo para identificar a linguagem predominante da publicação. O modelo estima a probabilidade de idioma do vídeo:

$$\text{Idioma}(V) = \text{FastText}(T_V \cup S_V)$$

Os vídeos com $y_\text{AI}(V) = 1$ e cujo idioma classificado é português (PT) ou inglês (EN) foram indexados positivamente e qualificados para a coleta de seus respectivos comentários. Todos os demais vídeos foram sumariamente descartados do corpus de análise.

2) Evolução Temporal do Volume de Vídeos: Para caracterizar a evolução temporal do volume de vídeos publicados sobre Inteligência Artificial em ambos os países ao longo do período do estudo (2021-2025), a Figura 1 apresenta a média móvel mensal (com janela de 3 meses) do número de vídeos selecionados no corpus final.

B. Extração e Pré-processamento de Comentários

Para cada um dos vídeos qualificados, a totalidade de comentários principais (*top-level comments*) e suas respectivas respostas encadeadas (*replies*) foram extraídos por meio da *YouTube Data API v3*. Posteriormente, os dados passaram por uma etapa de limpeza e pré-processamento estruturada para normalizar os caracteres Unicode, remover elementos promocionais e spams, e anonimizar de forma irreversível os atributos identificáveis dos usuários (como *handles*, *channel IDs*, URLs e endereços de e-mail), assegurando a conformidade ética com a Lei Geral de Proteção de Dados (LGPD - Lei nº 13.709/2018).

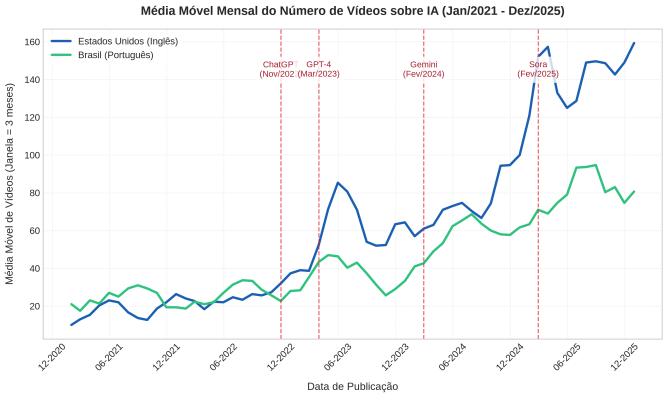


Fig. 1. Média móvel mensal do número de vídeos sobre IA. Eventos como o lançamento do ChatGPT, GPT-4, Gemini e Sora estão indicados.

C. Classificação dos Valores Humanos de Schwartz nas Transcrições

Para investigar a estrutura de valores incutida nos discursos dos criadores de conteúdo, os textos das transcrições foram analisados segundo a teoria dos **Valores Humanos Básicos de Schwartz**. Esta teoria descreve dez valores motivacionais universais organizados em uma estrutura circular contínua, que podem ser consolidados em quatro macrodimensões: *Auto-transcendência*, *Conservação*, *Abertura à Mudança* e *Auto-engrandecimento*.

Para a classificação automática dos valores nas transcrições, utilizou-se o classificador multi-rótulo pré-treinado `devnote5676/schwartz-values-classifier` disponibilizado publicamente no Hugging Face. Este modelo é baseado na arquitetura **DeBERTa-v3** (*Decoding-enhanced BERT with Disentangled Attention*) e foi finetunado especificamente para classificar sentenças segundo a estrutura de Valores Humanos Básicos de Schwartz, estimando a probabilidade de presença de cada um dos dez valores motivacionais para os segmentos de texto de entrada.

1) Configuração do Tokenizer e Algoritmo de Janela Deslizante: A fim de processar transcrições completas cujos comprimentos extrapolam o limite de entrada do modelo e manter a coerência das sentenças, desenvolveu-se um algoritmo de **janela deslizante com mapeamento dinâmico de offsets**.

O tokenizer nativo do DeBERTa-v3 emprega um algoritmo de tokenização por subpalavras baseado em SentencePiece com codificação de par de bytes (BPE), adotando um comprimento de entrada máximo de $N_\text{max} = 512$ tokens. A janela deslizante opera sob os seguintes parâmetros de controle:

- Comprimento da janela de tokens: $L_c = 400$
- Sobreposição (*overlap*) de tokens: $L_o = 50$
- Passo de avanço (*stride*): $S_\text{stride} = L_c - L_o = 350$

Seja S a string da transcrição bruta de um vídeo. O pipeline realiza as seguintes operações matemáticas para cada transcrição:

1) O tokenizer processa S, retornando uma sequência de identificadores de tokens $\mathbf{t} = (t_1, t_2, \ldots, t_M)$ e a matriz correspondente de mapeamento de offsets $\mathbf{o} = (o_1, o_2, \ldots, o_M)$, onde cada par $o_j = (s_j, e_j)$ determina as posições de caractere inicial e final de t_j na string original S.
2) Para cada bloco $k = 0, 1, \ldots, \left\lfloor \frac{M - L_o}{S_\text{stride}} \right\rfloor$, definem-se os limites dos índices dos tokens:
$$i_{\text{start}}(k) = k \cdot S_{\text{stride}}$$
$$i_{\text{end}}(k) = \min(i_{\text{start}}(k) + L_c, M)$$
3) Os índices de token são mapeados reversamente para as coordenadas de caracteres originais de S:
$$\text{CharStart}(k) = \begin{cases} 0, & \text{se } i_{\text{start}}(k) = 0 \\ o_{i_{\text{start}}(k)}[0], & \text{caso contrário} \end{cases}$$
$$\text{CharEnd}(k) = o_{i_{\text{end}}(k)-1}[1]$$
4) Extrai-se o chunk textual original C_k:
$$C_k = S[\text{CharStart}(k) : \text{CharEnd}(k)]$$

Nota: Este mapeamento dinâmico garante que o fatiamento ocorra nas fronteiras exatas dos tokens gerados, contudo preserva o texto bruto contínuo com todas as pontuações e espaçamentos originais.

2) Inferência e Agregação: Para cada fragmento C_k gerado, executa-se a classificação para cada um dos dez valores $\mathcal{V}_\text{Schwartz} = \{v_1, v_2, \ldots, v_10\}$. Constrói-se a string de entrada para o DeBERTa concatenando o rótulo do valor alvo ao texto do chunk:
$$\mathbf{x}_{v,C_k} = \texttt{"<"} \parallel v \parallel \texttt{"> [SEP] "} \parallel C_k$$
Onde $\parallel$ representa a concatenação de strings.

O modelo computa os logits de classificação para cada entrada, de modo que a probabilidade final de presença do valor v no fragmento C_k, indicada por $P(v \mid C_k)$, é estimada via normalização sigmoide:
$$P(v \mid C_k) = \sigma(z_{v,C_k}) = \frac{1}{1 + e^{-z_{v,C_k}}}$$

Se o classificador retornar a probabilidade s vinculada ao rótulo predito $L \in \{\text{positive}, \text{negative}\}$, ela é unificada da seguinte forma:
$$P(v \mid C_k) = \begin{cases} s, & \text{se } L = \text{positive} \\ 1 - s, & \text{se } L = \text{negative} \end{cases}$$

O indicador de presença binária $I(v, C_k) \in \{0, 1\}$ é computado com base no limiar $\theta = 0{,}5$:
$$I(v, C_k) = \begin{cases} 1, & \text{se } P(v \mid C_k) > 0{,}5 \\ 0, & \text{caso contrário} \end{cases}$$

Para agregar os dados ao nível do vídeo V, composto por K chunks, calcula-se a média aritmética das probabilidades e das prevalências de presença dos valores:
$$\text{MeanProb}(v \mid V) = \frac{1}{K} \sum_{k=1}^{K} P(v \mid C_k)$$

$$\text{Prevalence}(v \mid V) = \frac{1}{K} \sum_{k=1}^{K} I(v, C_k)$$

D. Análise Psicolinguística Baseada em Dicionários de Radicais

A expressão cognitiva, afetiva e social dos usuários nos comentários foi avaliada por meio de uma abordagem de dicionário psicolinguístico baseada na categorização conceitual da ferramenta clássica **LIWC** (*Linguistic Inquiry and Word Count*). Desenvolveu-se uma taxonomia de radicais (*stems*) customizada para português (PT) e inglês (EN), estruturada em seis dimensões linguísticas:

1) **Processos Sociais:** Termos relativos a coletividade, família, interações e diálogos.
2) **Processos Afetivos:** Palavras que representam sentimentos de afeto, ansiedade, raiva e emoções positivas/negativas.
3) **Processos Biológicos:** Vocábulos associados a percepções fisiológicas, sensações corpóreas e saúde.
4) **Motivações:** Foco semântico em conquistas, metas, aspirações, poder e aspectos monetários.
5) **Preocupações Pessoais:** Termos da vida cotidiana, como trabalho, estudos, religiosidade e lazer.
6) **Linguagem Informal:** Expressões cotidianas da internet, coloquialismos, gírias e interjeições.

A Tabela 1 apresenta a lista completa de radicais estruturada para ambos os corpora:

Tabela 3.1: Distribuição de radicais linguísticos nativos por categoria analítica.

1) Algoritmo Rápido de Correspondência de Radicais: Para viabilizar o processamento de milhões de registros com alta eficiência de memória e tempo de CPU, desenvolveu-se um algoritmo baseado na compilação em C de árvores de expressões regulares complexas.

Seja T um comentário. Primeiramente, realiza-se a tokenização léxica com a extração exclusiva de caracteres alfabéticos em caixa baixa por meio de busca por expressão regular, gerando a sequência de termos $\mathbf{W}_T = (w_1, w_2, \ldots, w_N)$, onde N é o total de palavras válidas.

Para cada uma das categorias psicológicas c, compila-se um padrão de expressão regular agrupando a união dos radicais correspondentes em uma única expressão disjunta, ancorada ao início do termo. O motor de expressões regulares executa o casamento dos radicais sob uma máquina de estados finitos linear. Define-se a função indicadora de casamento $m(w_i, c)$ como 1 se o termo w_i casa com o padrão da categoria c, e 0 caso contrário.

O cálculo do score normalizado Score_$c(T)$ do comentário T para a categoria c corresponde à proporção de termos casados em relação ao total de palavras válidas:

$$\text{Score}_c(T) = \frac{1}{N} \sum_{i=1}^{N} m(w_i, \text{Pattern}_c)$$

A execução computacional deste casamento possui complexidade temporal na ordem de $\mathcal{O}(N \cdot L)$, onde L é o comprimento médio de cada palavra w_i. Dado que L é assintoticamente pequeno, o processamento de um comentário de tamanho arbitrário ocorre em tempo linear $\mathcal{O}(N)$.

2) Alinhamento e Reconstrução Cross-Cultural dos Trechos em Português: Para comparar de forma isenta os discursos associados às classificações de valores executadas no DeBERTa-v3 (cujo modelo é nativo em inglês), o corpus em português foi primeiramente traduzido em nível de vídeo. Contudo, para evitar viés de tradução e falsas detecções ao calcular os scores psicolinguísticos nos dicionários LIWC, desenvolveu-se um algoritmo de **alinhamento geométrico de coordenadas de texto** para mapear os trechos preditos de volta ao português original:

1) Seja T_pt a string contínua da transcrição em português (extensão de caracteres L_pt) e T_en a transcrição traduzida em inglês (extensão L_en).
2) Para um determinado chunk em inglês C_k^{en}, localiza-se seu índice inicial de correspondência na transcrição traduzida: x_start $= T$_en.find(C_k^{en}).
3) Computa-se a escala geométrica de comprimento entre os dois corpora:
$$\gamma = \frac{L_{\text{pt}}}{L_{\text{en}}}$$
4) Estima-se a janela provável de caracteres correspondentes em português:
$$y'_{\text{start}} = \lfloor x_{\text{start}} \cdot \gamma \rfloor$$
$$y'_{\text{end}} = \lfloor (x_{\text{start}} + \text{len}(C_k^{\text{en}})) \cdot \gamma \rfloor$$
5) Ajustam-se os índices estimados às fronteiras naturais das palavras (espaços em branco) para assegurar a integridade lexical das palavras limítrofes:
$$y_{\text{start}} = \max(\{j \leq y'_{\text{start}} \mid T_{\text{pt}}[j] = \text{' '}\}) + 1$$
$$y_{\text{end}} = \min(\{j \geq y'_{\text{end}} \mid T_{\text{pt}}[j] = \text{' '}\})$$
6) O chunk em português original $C_k^{\text{pt}} = T$_pt$[y$_start : y_end$]$ é extraído e submetido diretamente aos radicais de português (\text{stems}_{\text{pt}}), blindando a análise contra artefatos linguísticos gerados pela tradução.

3) Testes de Hipóteses Estatísticas de Mann-Whitney U: Devido à forte assimetria das frequências de termos em comentários de mídias sociais e ao elevado percentual de scores nulos por categoria, as distribuições psicolinguísticas não apresentam normalidade. A comparação estatística transcultural das distribuições foi efetuada por meio do teste não-paramétrico de **Mann-Whitney U** (bicaudal).

Sejam $X = \{x_1, x_2, \ldots, x_n_1\}$ e $Y = \{y_1, y_2, \ldots, y_n_2\}$ amostras independentes dos scores psicolinguísticos para uma dada categoria c oriundas dos corpora em inglês (EN) e português (PT), respectivamente. O teste avalia a hipótese nula de igualdade estocástica:

TABLE I
DICIONÁRIO DE RADICAIS PSICOLINGUÍSTICOS ADAPTADOS

Categoria	Radicais em Português (PT)	Radicais em Inglês (EN)
Social	amigo, colega, pai, mãe, filho, filha, irmão, irmã, família, pessoas, grupo, criança, menino, menina, cara, mulher, homem, social, convers, fal, compartilh, nós, nosso, nossa	friend, buddy, parent, mother, mom, father, dad, brother, sister, family, people, group, child, kid, guy, girl, boy, woman, man, social, meet, talk, share, we, our, us
Afetivo	feliz, alegr, triste, chor, raiva, odi, am, gost, sint, sent, medo, assust, preocup, ansios, ruim, mal, bom, bem, ótimo, legal, esperança, confi	happy, glad, joy, sad, cry, angry, hate, love, like, feel, fear, scared, worry, anxious, bad, good, nice, great, awesome, hope, trust
Biológico	corpo, cabeça, braço, perna, olho, olhar, rosto, ouvir, ver, com, aliment, beb, dorm, sono, cansad, saúde, doent, dor, médico, físico	body, head, arm, leg, eye, face, hear, see, eat, food, drink, sleep, tired, health, sick, pain, hurt, doctor, physical
Motivações	conquist, ganh, sucess, falh, perd, meta, tent, trabalh, carreir, poder, control, lider, forç, recompens, dinheiro, compr, vend	achiev, win, success, fail, lose, goal, try, work, job, career, power, control, lead, rule, force, reward, gain, earn, money, buy, sell
Preocupações	casa, lar, escola, aula, aprend, estud, trabalh, dinheiro, grana, religi, deus, igreja, rez, fé, mort, morr, lazer, jog, brinc, filme, músic	home, house, school, class, learn, study, work, money, cash, job, religi, god, church, pray, faith, death, die, grave, leisur, play, game, movie, music
Informal	né, tá, ok, beleza, legal, cara, tipo, mano, véio, porra, merda, caralho, uau, ufa, oba	yeah, yep, okay, ok, cool, awesome, stuff, gonna, wanna, lol, omg, fuck, shit, damn, hell, guy, dude

- **Hipótese Nula (H_0):** A probabilidade de uma observação de X exceder uma de Y é idêntica à probabilidade de uma de Y exceder uma de X:

$$P(X > Y) = P(Y > X) = 0{,}5$$

- **Hipótese Alternativa (H_1):**

$$P(X > Y) \neq P(Y > X)$$

O cálculo do teste ordena conjuntamente todos os elementos de X e Y de 1 a n_1+n_2. A estatística de teste U_1 é obtida por:

$$U_1 = n_1 n_2 + \frac{n_1(n_1+1)}{2} - R_1$$

Onde R_1 representa o somatório das classificações posicionais (postos/ranks) atribuídas à amostra X. Sob aproximação normal decorrente do teorema central do limite para grandes amostras, calcula-se o score Z padronizado corrigido para empates de postos:

$$Z = \frac{U_1 - \frac{n_1 n_2}{2}}{\sqrt{\frac{n_1 n_2 (n_1+n_2+1)}{12}}}$$

O nível de rejeição crítico adota a significância clássica de $\alpha = 0{,}05$.

E. Métricas Descritivas e Nível de Esforço dos Comentários

Com o intuito de qualificar a recepção pública dos conteúdos de IA para além da simples contagem de engajamento superficial, projetou-se uma metodologia para categorizar os comentários segundo o seu **Nível de Esforço**. O esforço é tratado como uma *proxy* da profundidade do engajamento cognitivo e informacional exercido pelos usuários ao formularem suas reações.

1) Atributos Estruturais e de Expressividade: Extraem-se três atributos booleanos de expressividade textual de cada comentário T:

- **Presença de Interrogação ($I_q \in \{0,1\}$):** retorna 1 se o caractere `'?'` pertence ao comentário T, e 0 caso contrário.
- **Presença de Exclamação ($I_excl \in \{0,1\}$):** retorna 1 se o caractere `'!'` pertence ao comentário T, e 0 caso contrário.
- **Presença de Emojis ($I_emoji \in \{0,1\}$):** retorna 1 se o comentário T contém ao menos um pictograma/emoji, e 0 caso contrário.

O índice de expressividade estrutural agregada do comentário ($I_struct(T)$) é definido logicamente pela disjunção dos atributos individuais:

$$I_{struct}(T) = I_q(T) \vee I_{excl}(T) \vee I_{emoji}(T)$$

2) Classificação Heurística Disjunta de Esforço: Seja $W(T)$ o número total de termos obtidos pela quebra do comentário por espaços em branco. O comentário T é mapeado exclusivamente para uma das três categorias ordinais de esforço, $\text{Esforço}(T) \in \{\text{Baixo}, \text{Médio}, \text{Alto}\}$, segundo as seguintes condições lógicas:

- **Alto:** se $W(T) > 20$.
- **Médio:** se $(5 \leq W(T) \leq 20)$ ou se $(W(T) < 5$ e $I_struct(T) = 1)$.
- **Baixo:** se $W(T) < 5$ e $I_struct(T) = 0$.

A fundamentação teórica de cada nível é descrita na Tabela 3.2:

Tabela 3.2: Matriz operacional de níveis de esforço de comentários.

3) Análise de Engajamento e Reação: Para quantificar a receptividade de cada vídeo, cruzam-se os perfis de distribuição dos níveis de esforço com a quantidade de curtidas de cada comentário ($L(T)$) e sua respectiva extensão em palavras. Isso viabiliza medir a tração social que discursos altamente

TABLE II
CLASSIFICAÇÃO DO NÍVEL DE ESFORÇO COGNITIVO NOS COMENTÁRIOS

Nível de Esforço	Critério de Classificação	Significado Teórico / Proxy de Recepção
Baixo Esforço	$W(T) < 5$ e $I_struct(T) = 0$	**Reação Passiva:** Representa reações imediatas ou monossilábicas (e.g. "excelente", "muito bom", "show"). Sinaliza baixa elaboração crítica do conteúdo visualizado.
Médio Esforço	$5 \leq W(T) \leq 20$ ou ($W(T) < 5$ e $I_struct(T) = 1$)	**Interação Expressiva:** Comentários com extensão mediana ou textos muito curtos que fazem uso ativo de marcadores afetivos e de interação (perguntas e emojis), indicando reatividade comunicativa básica ao conteúdo.
Alto Esforço	$W(T) > 20$	**Engajamento Cognitivo Profundo:** Textos longos estruturados com encadeamento de ideias, argumentações complexas, relatos de vivências ou contra-argumentações sobre os impactos da IA.

reflexivos ou reações de baixo esforço geram na comunidade em cada um dos corpora analisados.

IV. RESULTADOS E DISCUSSÃO

Este capítulo apresenta e discute os resultados empíricos obtidos a partir das análises quantitativas, qualitativas e computacionais aplicadas aos corpora de transcrições de vídeos (oferta de conteúdo) e de comentários (recepção do público) do YouTube. O capítulo divide-se em duas seções principais: a primeira detalha a análise das narrativas dos criadores de conteúdo com base nos Valores Humanos de Schwartz e nos atributos psicolinguísticos; a segunda investiga a percepção do público a partir das métricas de engajamento, expressividade e níveis de esforço cognitivo identificados nos comentários.

A. Análise das Transcrições (Narrativas dos Criadores)

Para mapear as estruturas de valor subjacentes aos discursos dos criadores de conteúdo sobre Inteligência Artificial, analisou-se o corpus de transcrições segmentado em janelas deslizantes (*sliding windows*). O corpus em inglês (EN) compreende **30.961 fragmentos** (*chunks*), enquanto o corpus em português (PT) totaliza **20.334 fragmentos**.

1) Prevalência dos Valores Humanos de Schwartz: A classificação multi-rótulo baseada no modelo DeBERTa-v3 estimou a presença e os scores contínuos de probabilidade dos 10 valores motivacionais da teoria de Schwartz em cada fragmento de fala. A Tabela 4.1 apresenta a comparação transcultural das taxas de prevalência (proporção de *chunks* com probabilidade $P(V_j) > 0,5$) e as médias das probabilidades obtidas nos dois idiomas.

Tabela 4.1: Prevalência e Média de Probabilidades dos Valores de Schwartz (EN vs. PT).

Os dados revelam que o **Universalismo** e a **Realização** dominam amplamente os discursos em ambos os corpora. A Realização, presente em 65,74% dos trechos em inglês e 58,85% em português, reflete o enquadramento técnico e instrumental da Inteligência Artificial. Os criadores concentram seus discursos na demonstração de competências, na otimização algorítmica, no alcance de resultados eficientes e na superação de capacidades analíticas anteriores (capacidade de *achievement*).

Por outro lado, a alta prevalência de Universalismo (80,46% em EN e 72,28% em PT) atesta que a discussão sobre IA não se limita a métricas de desempenho técnico. Há uma forte incorporação de debates éticos, impactos sociais distributivos, riscos de vieses algorítmicos e a necessidade de democratização tecnológica. A Inteligência Artificial é representada não apenas como um motor de produtividade, mas como um elemento de profunda transformação social, cujos impactos éticos devem ser ponderados de forma coletiva.

A **Autodireção** desponta como o terceiro valor mais prevalente (30,93% em EN e 21,32% em PT). Na teoria de Schwartz, a Autodireção envolve a busca por independência de pensamento, criatividade e liberdade de escolha. Nos discursos de IA, este valor materializa-se na ênfase dada ao aprendizado autônomo, ao desenvolvimento autoral de ferramentas (*DIY - Do It Yourself*), à flexibilidade cognitiva e à exploração livre de novas soluções computacionais.

Observa-se que, sistematicamente, o corpus em inglês apresenta scores médios e taxas de prevalência superiores aos do corpus em português para quase a totalidade dos valores (com exceção de Tradição). Esse comportamento sugere que o discurso anglófono é mais multifacetado e semanticamente denso no enquadramento de múltiplos motivadores simultâneos, enquanto os criadores lusófonos adotam narrativas ligeiramente mais contidas e focadas em eixos específicos.

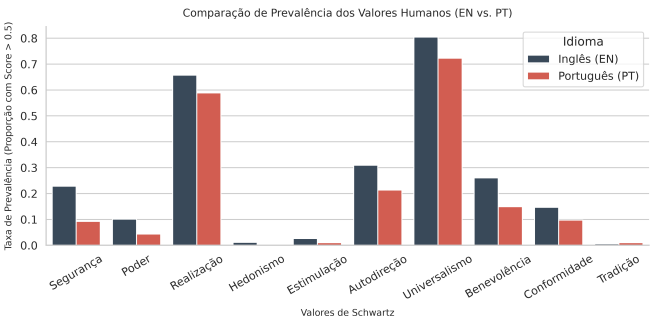


Fig. 2. Comparação de Prevalência dos Valores Humanos (EN vs. PT)

2) Macrodimensões Motivacionais: Schwartz organiza os 10 valores em quatro grandes macrodimensões motivacionais complementares e conflitantes de nível superior. A Tabela 4.2 e a análise agregada consolidam os scores das macrodimensões.

Tabela 4.2: Médias das Macrodimensões de Valores Humanos (EN vs. PT).

A macrodimensão de **Autotranscendência** configura-se como o principal polo norteador do discurso dos criadores

TABLE III
PREVALÊNCIA E MÉDIA DE PROBABILIDADE DOS VALORES DE SCHWARTZ

Valor de Schwartz	Prevalência - EN (%)	Prevalência - PT (%)	Média de Prob. - EN	Média de Prob. - PT
Universalismo	80,46%	72,28%	0,7256	0,6563
Realização	65,74%	58,85%	0,6375	0,5693
Autodireção	30,93%	21,32%	0,3315	0,2517
Benevolência	26,04%	14,94%	0,2896	0,2098
Segurança	22,80%	9,22%	0,2582	0,1307
Conformidade	14,69%	9,75%	0,1632	0,1231
Poder	10,07%	4,36%	0,1286	0,0721
Estimulação	2,63%	1,04%	0,0501	0,0265
Hedonismo	1,12%	0,41%	0,0190	0,0087
Tradição	0,60%	0,98%	0,0166	0,0236

TABLE IV
SCORE MÉDIO DAS MACRODIMENSÕES DE SCHWARTZ

Macrodimensão de Schwartz	Valores Integrantes	Score Médio - EN	Score Médio - PT
Autotranscendência	Universalismo, Benevolência	0,5076	0,4330
Auto-engrandecimento	Realização, Poder	0,3831	0,3207
Conservação	Segurança, Conformidade, Tradição	0,1460	0,0925
Abertura à Mudança	Autodireção, Estimulação, Hedonismo	0,1335	0,0956

em ambos os idiomas (0,5076 em EN e 0,4330 em PT), secundada pelo **Auto-engrandecimento** (0,3831 em EN e 0,3207 em PT). Sob a ótica teórica de Schwartz, estas duas dimensões estabelecem um conflito motivacional direto: enquanto o Auto-engrandecimento enfatiza a busca por interesses pessoais, sucesso individual e controle, a Autotranscendência prioriza o bem-estar coletivo, a justiça social e a igualdade de oportunidades.

A coexistência proeminente de ambos os eixos no discurso sobre IA ilustra a natureza dual desse ecossistema técnico. Os criadores operam em um constante tensionamento dialético: celebram os avanços comerciais, a eficiência de mercado e o monopólio corporativo das Big Techs (Auto-engrandecimento), ao mesmo tempo em que demandam regulação, responsabilidade civil, alinhamento ético e prevenção contra danos sociais causados pelos mesmos sistemas (Autotranscendência).

As dimensões de **Conservação** e **Abertura à Mudança** registram scores significativamente mais baixos. Isso indica que discursos ancorados na preservação de estruturas sociais rígidas e dogmas culturais (Conservação) ou orientados exclusivamente para o prazer sensorial e novidades lúdicas sem propósito instrumental (Abertura à Mudança) são periféricos no ecossistema de vídeos de tecnologia analisado.

3) Relação entre Valores e Engajamento: Para investigar de que maneira os perfis de valores humanos expressos no discurso dos criadores associam-se à recepção prática dos vídeos, aplicou-se o coeficiente de correlação de postos de Spearman (r_s). A escolha deste teste estatístico não-paramétrico justifica-se pela sua robustez frente a distribuições não-lineares, altamente assimétricas e com presença de *outliers* extremos, características típicas de métricas de engajamento em redes sociais (como contagens de visualizações e comentários, que frequentemente seguem distribuições de cauda

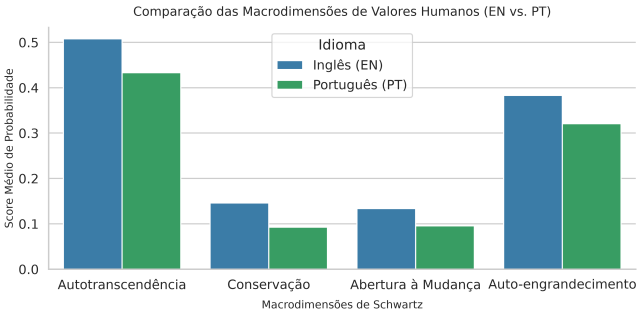


Fig. 3. Comparação das Macrodimensões (EN vs. PT)

longa ou leis de potência).

O coeficiente de Spearman avalia a relação de monotonicidade entre duas variáveis com base em seus postos ordenados (ranks), sendo definido matematicamente como:

$$r_s = 1 - \frac{6 \sum d_i^2}{n(n^2 - 1)}$$

onde d_i representa a diferença entre os postos de cada observação nas duas variáveis analisadas, e n o número de pares amostrais. O coeficiente varia no intervalo $[-1, 1]$, onde $r_s = 1$ indica uma relação monótona crescente perfeita, $r_s = -1$ uma relação monótona decrescente perfeita, e $r_s = 0$ a total ausência de associação monótona. Nesta análise, correlacionou-se a probabilidade média predita para cada valor de Schwartz no vídeo com o volume bruto de visualizações (`view\_count`, indicativo de consumo passivo) e o volume bruto de comentários (`comment\_count`, representativo de engajamento ativo).

A Tabela 4.3 apresenta os coeficientes calculados para ambos os idiomas. Devido ao elevado tamanho amostral

de vídeos analisados, todas as correlações discutidas abaixo apresentaram significância estatística rigorosa ($p < 0,01$).

Tabela 4.3: Coeficientes de Correlação de Spearman (r_s) entre Valores de Schwartz e Métricas de Engajamento.

Em estudos de redes sociais e comportamento online, coeficientes de correlação situados no intervalo de $|r_s| \in [0,05; 0,20]$ são convencionalmente interpretados como de magnitude fraca ou modesta. Contudo, em ambientes digitais de alta complexidade, a variância do engajamento é sobredeterminada por uma multiplicidade de fatores externos não-controlados (como o design de miniaturas, heurísticas de recomendação algorítmica, sazonalidade e histórico do canal). Sob tais condições de ruído inerente, a detecção de coeficientes fracos porém consistentes e estatisticamente significativos aponta para tendências comportamentais sistemáticas e generalizáveis sobre como o enquadramento valorativo afeta a repercussão pública:

1) **Associação Monótona Positiva no Efeito Lúdico-Sensacionalista (Hedonismo e Estimulação):** Observa-se uma associação monótona positiva fraca com o volume de visualizações para os valores de **Hedonismo** (EN: $r_s = 0,1348$; PT: $r_s = 0,0650$) e **Estimulação** (EN: $r_s = 0,1190$; PT: $r_s = 0,0389$). Esse comportamento aponta que discursos focados em entretenimento puro, inovações disruptivas e elementos surpreendentes de IA possuem uma relação monótona crescente com o consumo passivo de massa.
2) **Associação Monótona Negativa nos Debates Éticos (Universalismo e Benevolência):** Em contrapartida, o **Universalismo** e a **Benevolência** demonstram uma correlação monótona decrescente com a contagem de visualizações, sendo mais pronunciada no corpus anglófono (Universalismo: $r_s = -0,1150$; Benevolência: $r_s = -0,1563$). Este comportamento indica de forma estatisticamente rigorosa que enquadramentos focados em responsabilidade social, dilemas éticos e impactos ecológicos tendem a repelir audiências de massa espontâneas, restringindo-se a nichos mais focados.
3) **Engajamento Dialético Ativo via Valores de Tradição e Poder:** A **Tradição** apresenta o coeficiente de correlação positivo mais expressivo no tocante ao volume de comentários em ambos os idiomas (EN: $r_s = 0,1614$; PT: $r_s = 0,1131$). Isso estabelece que discursos que tensionam as práticas tradicionais humanas, artesanais ou religiosas diante do avanço da IA induzem uma resposta ativa e argumentativa do público na seção de comentários. No ecossistema norte-americano, o valor de **Poder** correlaciona-se positivamente com comentários ($r_s = 0,1161$), evidenciando o apelo crítico do debate sobre a centralização de capital e a hegemonia tecnológica das corporações de tecnologia.
4) **Assimetria Transcultural e Monotonicidade Inversa da Realização e Autodireção:** No corpus em português, diferentemente do inglês, a **Realização** ($r_s = -0,1433$ para visualizações; $r_s = -0,1497$ para comentários) e a **Autodireção** ($r_s = -0,1213$ para visualizações; $r_s = -0,1308$ para comentários) possuem associações monótonas negativas bem delimitadas com ambas as métricas. Este resultado revela que vídeos de teor eminentemente técnico (tutoriais, programação formal) no Brasil encontram barreiras para atingir o público amplo, correlacionando-se sistematicamente a um menor tráfego absoluto de engajamento na plataforma.

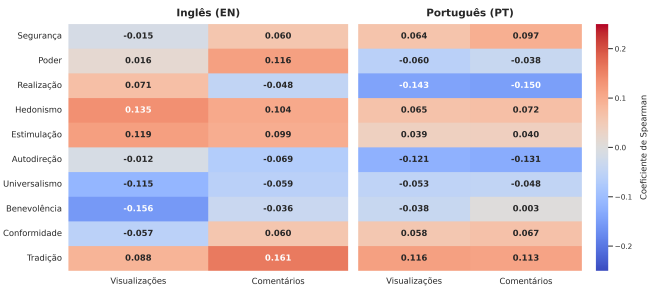


Fig. 4. Correlação de Spearman com Engajamento

4) Distribuição de Valores por Tópicos Semânticos: A categorização dos vídeos em macro-tópicos semânticos permitiu cruzar os perfis temáticos com as probabilidades médias dos valores de Schwartz associados, mapeando as estratégias de enquadramento narrativo de acordo com o assunto abordado (Tabela 4.4).

Tabela 4.4: Média de Valores de Schwartz por Macro-Tópico Semântico (Top 5 Tópicos por Idioma).

Os dados indicam que o tópico **AI models** (como anúncios e análises de novos modelos de linguagem GPT, Claude ou Gemini) é o enquadramento de maior score para **Realização** tanto em inglês (0,7450) instruído quanto em português (0,6611). Isso reforça que as discussões em torno de modelos de IA centram-se na superação técnica e nos testes de benchmark.

No corpus em inglês, o tópico **fears** (temores associados ao descontrole algorítmico, apocalipse tecnológico ou obsolescência humana) apresenta o maior score médio para o **Universalismo** (0,7794) e alto score de **Segurança** (0,2775). Isso sugere que o enquadramento do ”medo” em inglês não é puramente alarmista, mas vem acompanhado de demandas éticas coletivas e da necessidade de estabelecimento de marcos regulatórios seguros para salvaguardar a humanidade.

O tópico **business/money** em inglês registra o maior índice de preocupação com a **Segurança** (0,2863), refletindo a ansiedade em relação à estabilidade econômica individual, à perda de postos de trabalho e aos riscos financeiros trazidos pela automação.

Em português, o tópico **programming** destaca-se fortemente pelos elevados índices de **Realização** (0,7130) e **Autodireção** (0,3234). Em vídeos de programação, a Inteligência Artificial é abordada sob um viés prático e de capacitação individual, com foco no aumento de eficiência pessoal do programador e na sua capacidade de criação autônoma de sistemas.

TABLE V
CORRELAÇÃO DE SPEARMAN ENTRE VALORES DE SCHWARTZ E ENGAJAMENTO

Valor de Schwartz	Visualizações (EN)	Comentários (EN)	Visualizações (PT)	Comentários (PT)
Segurança	-0,0147	0,0601	0,0640	0,0972
Poder	0,0156	0,1161	-0,0596	-0,0382
Realização	0,0711	-0,0481	-0,1433	-0,1497
Hedonismo	0,1348	0,1037	0,0650	0,0717
Estimulação	0,1190	0,0990	0,0389	0,0401
Autodireção	-0,0121	-0,0694	-0,1213	-0,1308
Universalismo	-0,1150	-0,0592	-0,0527	-0,0477
Benevolência	-0,1563	-0,0355	-0,0378	0,0034
Conformidade	-0,0572	0,0597	0,0576	0,0666
Tradição	0,0881	0,1614	0,1163	0,1131

TABLE VI
DISTRIBUIÇÃO DOS VALORES MÉDIOS POR TÓPICO SEMÂNTICO

Idioma	Tópico Semântico	Chunks	Realização	Autodireção	Universalismo	Segurança
EN	*AI celebrities or companies*	8.851	0,5699	0,3670	0,7032	0,2272
	business/money	6.805	0,6680	0,3073	0,7318	0,2863
	AI models	6.748	0,7450	0,3346	0,7381	0,1495
	devices/softwares	6.284	0,6430	0,3503	0,6291	0,2236
	fears	4.889	0,5428	0,3405	0,7794	0,2775
PT	*AI models*	6.386	0,6611	0,2826	0,6480	0,0936
	devices/softwares	4.549	0,5976	0,2538	0,6038	0,1336
	programming	3.908	0,7130	0,3234	0,6380	0,0867
	AI celebrities or companies	3.820	0,5313	0,2398	0,6569	0,1316
	AI	3.075	0,5799	0,2654	0,6643	0,1267

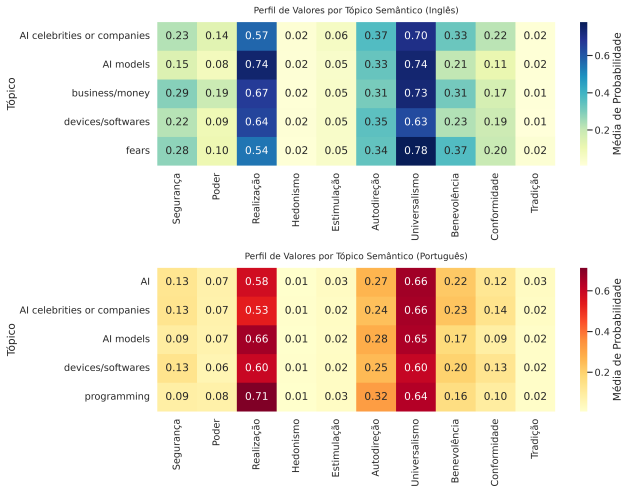


Fig. 5. Perfil de Valores por Tópico Semântico

5) Redes de Co-ocorrência de Valores e Restrições Topológicas: Para decodificar as estruturas discursivas sob uma perspectiva relacional e estrutural, modelou-se o corpus como uma rede de co-ocorrência baseada no coeficiente de similaridade de Jaccard (J) entre as atribuições dos valores de Schwartz. Em um problema de classificação multi-rótulo, em que múltiplos valores podem ser detectados concorrentemente em um mesmo segmento de texto, a similaridade de Jaccard entre dois valores de Schwartz, V_i e V_j, é formalizada como a razão entre o número de fragmentos (*chunks*) nos quais ambos os valores estão presentes (interseção) e o número de fragmentos nos quais pelo menos um deles ocorre (união):

$$J(V_i, V_j) = \frac{|V_i \cap V_j|}{|V_i \cup V_j|} = \frac{N(P(V_i) > 0,5 \wedge P(V_j) > 0,5)}{N(P(V_i) > 0,5 \vee P(V_j) > 0,5)}$$

O emprego do índice de Jaccard é tecnicamente vantajoso em relação a outras métricas de associação simples (como a concordância percentual absoluta), pois exclui as ausências conjuntas da contagem (casos em que ambos os valores são classificados como zero). Em corpora de texto caracterizados pela esparsidade de rótulos positivos, as ausências conjuntas tendem a inflar artificialmente a correlação percebida, um viés metodológico mitigado pelo foco exclusivo da similaridade de Jaccard na relação de interseção sobre união.

O grafo resultante foi espacializado impondo-se as restrições topológicas do modelo circular de Shalom Schwartz. De acordo com a teoria dos Valores Humanos Básicos, os dez valores motivacionais organizam-se em uma estrutura circular contínua que representa um *continuum* motivacional e dinâmico. A hipótese central dessa disposição topológica estabelece que valores adjacentes expressam objetivos motivacionais compatíveis e associados, ao passo que valores posicionados em extremos opostos do diâmetro representam motivações conflitantes e excludentes.

A análise topológica da rede revelou uma convergência estatística precisa com o modelo teórico de Schwartz em

ambos os idiomas, evidenciada pelos seguintes padrões de conectividade:

- **Densidade em Vizinhanças Adjacentes:** As arestas de maior peso Jaccard (representadas graficamente por maior espessura) concentram-se de forma quase exclusiva entre nós espacialmente contíguos na projeção circular. Observa-se uma forte densidade na conexão entre **Benevolência e Universalismo** ($J \approx 0,28$), constituindo a espinha dorsal da macrodimensão de Autotranscendência. De igual modo, a adjacência entre **Realização e Autodireção** e entre **Segurança e Conformidade** estabelece eixos de alta co-ocorrência.
- **Ausência de Arestas Cruzadas e Oposição Diamétrica:** De maneira estatisticamente notável, as conexões entre valores diametralmente opostos no círculo motivacional (com distância angular aproximada de $180°$) apresentam pesos nulos ou estatisticamente negligenciáveis (índice de Jaccard $J < 0,02$). Criadores raramente ou nunca co-ocorrem discursos baseados em **Poder** (hegemonia, controle de recursos) e **Benevolência** (bem-estar do grupo de referência) ou **Realização** (sucesso individual instrumental) e **Universalismo** (justiça social coletiva) no âmbito de um mesmo *chunk* semântico de 400 tokens.

Este fenômeno pode ser justificado teoricamente pelas restrições cognitivas e narrativas da comunicação: para que um fragmento de discurso mantenha a sua coerência pragmática, ele deve estar fundamentado em uma orientação motivacional homogênea. A introdução simultânea de motivadores diametralmente opostos em uma janela curta de fala geraria dissonância semântica e narrativa, resultando na perda de legibilidade e de coerência discursiva. Assim, a topologia circular de Schwartz funciona como uma restrição estrutural que condiciona a probabilidade de transição e co-ocorrência dos temas narrados pelos criadores de conteúdo.

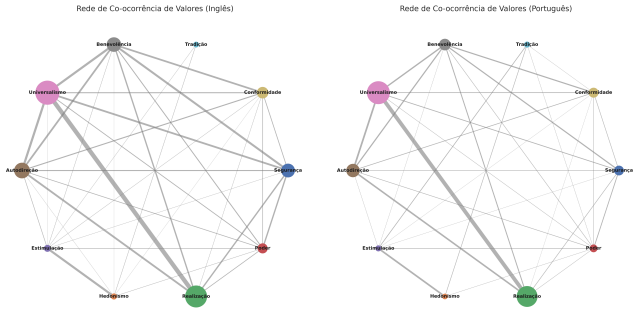


Fig. 6. Rede de Co-ocorrência de Valores

6) Análise Psicolinguística Transcultural (Atributos Baseados no LIWC): Visando identificar estilos discursivos e processos psicológicos embutidos nas narrativas, extraíram-se as frequências relativas de termos alinhados a seis dimensões psicolinguísticas estruturadas por dicionários nativos de radicais (*stems*). Para avaliar a significância estatística das variações transculturais observadas entre os corpora de inglês (EN) e português (PT), aplicou-se o teste não-paramétrico de Mann-Whitney U (também conhecido como teste de soma de postos de Wilcoxon).

A escolha do teste de Mann-Whitney U fundamenta-se na natureza não-normal e fortemente assimétrica das distribuições das frequências relativas das categorias psicolinguísticas, o que inviabiliza o uso de testes paramétricos baseados em médias (como o teste t de Student). O procedimento operacional do teste consiste no agrupamento (*pooling*) de todas as observações dos dois corpora ($N_1 = 30.961$ para EN e $N_2 = 20.334$ para PT), seguido pela ordenação conjunta dos dados em postos (ranks) crescentes (de 1 a $N_1 + N_2$), em que valores idênticos (empates) recebem a média dos postos que ocupariam. A estatística de teste para cada grupo é calculada pelas equações:

$$U_1 = N_1 N_2 + \frac{N_1(N_1+1)}{2} - R_1$$

$$U_2 = N_1 N_2 + \frac{N_2(N_2+1)}{2} - R_2$$

onde R_1 e R_2 correspondem à soma dos postos atribuídos às observações dos grupos 1 e 2, respectivamente. A estatística final do teste é dada por $U = \min(U_1, U_2)$.

A análise foi conduzida sob uma abordagem **bicaudal** (two-tailed), cuja hipótese nula (H_0) postula que a probabilidade de uma observação extraída aleatoriamente do grupo EN ser maior do que uma observação do grupo PT é idêntica à probabilidade inversa ($P(X_\text{EN} > X_\text{PT}) = 0,5$), ou seja, as distribuições de probabilidade de ambos os grupos são idênticas. A hipótese alternativa (H_1) assume a presença de dominância estocástica em qualquer direção ($P(X_\text{EN} > X_\text{PT}) \neq 0,5$).

A Tabela 4.5 apresenta as métricas descritivas de tendência central (médias e medianas), os valores calculados da estatística U e os respectivos níveis de significância (*p-value*). Devido à elevada dimensão dos corpora, as distribuições amostrais aproximam-se da normalidade assintótica via Teorema Central do Limite, viabilizando o cálculo preciso de p-values extremamente pequenos.

Tabela 4.5: Atributos Psicolinguísticos nas Transcrições e Teste de Mann-Whitney U (EN vs. PT).

O teste de Mann-Whitney U demonstrou que, para todas as seis categorias psicolinguísticas avaliadas, o *p-value* situa-se muito abaixo do limiar de significância nominal de $\alpha = 0,01$ ($p < 0,001$, com valores exatos atingindo a ordem de $2,502 \times 10^{-67}$ para Motivações e $6,199 \times 10^{-90}$ para Preocupações Pessoais). A obtenção de p-values desta magnitude nos permite rejeitar a hipótese nula H_0 com máxima confiança estatística, atestando que as diferenças nas distribuições de frequência das categorias psicolinguísticas não são fruto de flutuações amostrais aleatórias, mas sim de discrepâncias sistemáticas na estruturação comunicativa e nos processos mentais refletidos nos discursos transculturais dos criadores.

A análise interpretativa dessas variações revela nuances estruturais cruciais dos idiomas e estilos comunicativos dos criadores locais:

TABLE VII
RESULTADOS DO TESTE DE MANN-WHITNEY U PARA CATEGORIAS PSICOLINGUÍSTICAS

Categoria Psicolinguística	Média - EN (%)	Média - PT (%)	Mediana - EN (%)	Mediana - PT (%)	Estatística U	*p-value*
Processos Sociais	3,45%	1,69%	3,19%	1,42%	499.566.128,5	$p < 0,001$
Processos Afetivos	1,49%	0,92%	1,08%	0,75%	388.252.426,0	$p < 0,001$
Processos Biológicos	0,61%	2,39%	0,52%	2,26%	47.195.021,0	$p < 0,001$
Motivações	0,81%	0,70%	0,61%	0,52%	343.116.090,5	$2,502 \times 10^{-67}$
Preocupações Pessoais	0,73%	0,63%	0,54%	0,44%	347.452.627,0	$6,199 \times 10^{-90}$
Linguagem Informal	0,47%	2,28%	0,27%	2,09%	82.736.920,0	$p < 0,001$

1) **Predominância de Linguagem Informal em Português:** A frequência de Linguagem Informal é drasticamente superior no corpus em português (Média = 2,28%, Mediana = 2,09%) em comparação ao inglês (Média = 0,47%, Mediana = 0,27%). Isso atesta que os criadores de conteúdo brasileiros adotam um estilo de comunicação mais coloquial, utilizando com alta recorrência marcadores discursivos e gírias de internet (como *"né"*, *"tá"*, *"cara"*, *"tipo"*, *"beleza"*). Esse enquadramento busca reduzir a distância social entre o criador e a audiência, facilitando a recepção de assuntos complexos sobre IA por meio de uma linguagem acolhedora.
2) **Processos Biológicos como Marcadores Discursivos (PT):** O corpus em português apresenta índices de Processos Biológicos consideravelmente mais elevados (Média = 2,39% vs. 0,61% em EN). Essa diferença não decorre de discussões de saúde física propriamente dita, mas reflete o estilo linguístico da oratória lusófona, que utiliza repetidamente verbos de percepção física como marcadores discursivos e imperativos conversacionais (como *"vamos ver"*, *"olha só"*, *"escuta o que ele diz"*).
3) **Assimetria Gramatical em Processos Sociais:** A contagem bruta de Processos Sociais em inglês apresenta medianas significativamente mais altas na Tabela 4.5 (3,19% vs. 1,42% em PT). Sob uma ótica linguística, essa variação é explicada pela estrutura gramatical não-pro-drop do inglês, que exige a presença explícita de sujeitos e pronomes sociais em todas as orações (como *"we"*, *"us"*, *"our"*, *"people"*), inflando artificialmente as ocorrências do dicionário. No português (língua pro-drop), a flexão verbal permite a omissão de pronomes, resultando em menor frequência bruta na contagem direta por dicionário, muito embora as reações tipográficas da audiência (Seção 4.2.2) revelem que o discurso brasileiro é marcadamente mais expressivo e interpersonal na prática.

7) Evolução Temporal dos Valores (2021-2025): A evolução temporal das médias de probabilidade dos quatro principais valores identificados (Realização, Autodireção, Universalismo e Segurança) ao longo do período de 2021 a 2025 delineia a transição histórica e a maturidade tecnológica no discurso sobre Inteligência Artificial.

Tabela 4.6: Evolução das Médias das Probabilidades de Valores por Ano (EN vs. PT).

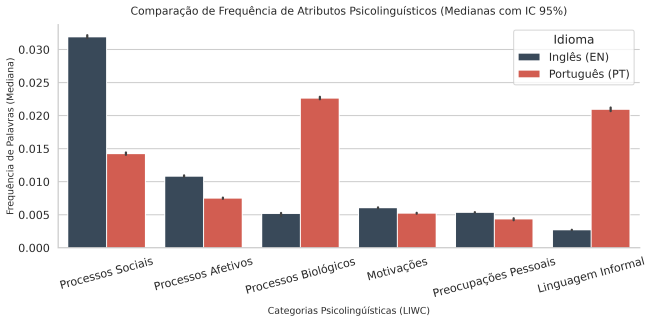


Fig. 7. Comparação de Atributos Psicolinguísticos

Os dados revelam que o ano de **2025** representa um marco de virada discursiva drástica em ambos os ecossistemas. Entre 2021 e 2024, a Realização e a Autodireção mantiveram patamares estáveis de prevalência. Em 2025, ocorre uma forte elevação: a Realização salta para 0,7102 em inglês e 0,7004 em português, acompanhada por um aumento expressivo da Autodireção no corpus brasileiro (de 0,2060 para 0,3142).

Esse salto temporal coincide com a estabilização e a integração no cotidiano de sistemas de IA generativos maduros. Os discursos dos criadores de conteúdo abandonaram conjecturas teóricas e notícias especulativas (comuns nas fases iniciais de 2022 e 2023 pós-lançamento do ChatGPT) para focar no desenvolvimento prático, na integração operacional de código, nas novas APIs e no sucesso prático do uso de agentes de IA na indústria (disparando a Realização). O expressivo aumento de Autodireção no Brasil sinaliza uma maior apropriação e apropriação técnica da tecnologia por parte dos criadores locais, focando em "como construir" de forma criativa e autônoma.

O Universalismo e a Segurança também apresentaram elevações em 2025, refletindo que a consolidação prática das ferramentas exigiu, de forma paralela, um debate urgente e estruturado sobre regulamentação legal de direitos autorais e alinhamento de segurança (*AI safety*).

B. Análise dos Comentários (Percepção do Público)

Para avaliar a recepção do público e a percepção pública em relação às narrativas descritas anteriormente, analisou-se a base de comentários associada. O corpus consolidado compreende **354.534 comentários em inglês** e **168.518 comentários em português**, totalizando **523.052 registros**.

TABLE VIII
EVOLUÇÃO TEMPORAL DOS SCORES MÉDIOS DE VALORES DE SCHWARTZ (2021-2025)

Ano	Realização (EN)	Realização (PT)	Autodireção (EN)	Autodireção (PT)	Universalismo (EN)	Universalismo (PT)	Segurança (EN)	Segura
2021	0,5927	0,4963	0,3422	0,1962	0,7586	0,6412	0,3102	0,
2022	0,6010	0,3997	0,3161	0,1985	0,7058	0,6334	0,2341	0,
2023	0,6151	0,5087	0,3515	0,2278	0,7381	0,6398	0,2360	0,
2024	0,5467	0,4895	0,3301	0,2060	0,6893	0,5950	0,2287	0,
2025	0,7102	0,7004	0,3249	0,3142	0,7402	0,7091	0,2817	0,

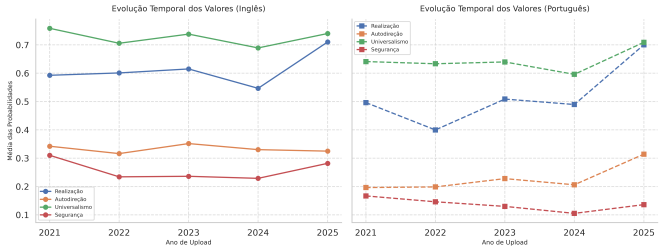


Fig. 8. Evolução Temporal dos Valores

1) Métricas Descritivas dos Comentários e Engajamento: A Tabela 4.7 consolida as métricas estruturais e de repercussão identificadas nos comentários coletados.

Tabela 4.7: Métricas Descritivas e Indicadores dos Comentários (EN vs. PT).

TABLE IX
MÉTRICAS DESCRITIVAS E DE EXPRESSIVIDADE DO CORPUS DE COMENTÁRIOS

Métrica Analisada	Inglês (EN)	Português (PT)
Total de Comentários	354.534	168.518
Mediana de Palavras	12	12
Média de Curtidas (*Likes*)	45,86	14,41
Taxa de Emojis (%)	9,98%	11,94%
Taxa de Perguntas (%)	16,24%	15,08%
Taxa de Exclamações (%)	11,59%	15,59%
Nível de Esforço Baixo (%)	21,79%	20,72%
Nível de Esforço Médio (%)	27,08%	29,47%
Nível de Esforço Alto (%)	51,13%	49,81%

Os dados evidenciam que, apesar das diferenças populacionais gritantes entre as audiências, existem semelhanças estruturais profundas na dinâmica de interação da plataforma. A **mediana de palavras por comentário é de exatamente 12 palavras** em ambos os idiomas. Esse alinhamento revela a existência de restrições de formato inerentes à plataforma do YouTube e a hábitos de escrita e leitura de mídias digitais que transcendem fronteiras nacionais.

A média de curtidas por comentário, no entanto, mostra-se consideravelmente maior em inglês (45,86 likes vs. 14,41 em português). Essa disparidade quantitativa reflete diretamente o maior volume populacional e de tráfego do público anglófono no YouTube, gerando um efeito de rede que amplifica o engajamento numérico de vídeos globais.

2) Indicadores Estruturais de Expressividade: Os marcadores sintáticos e tipográficos extraídos evidenciam divergências de comportamento e expressividade transculturais significativas:

- **Taxa de Emojis (Visual):** A presença de símbolos visuais (emojis) é de 11,94% nos comentários em português contra 9,98% em inglês, indicando uma maior expressividade pictográfica por parte da audiência brasileira.
- **Taxa de Exclamações (Afeto):** O uso de exclamações é acentuadamente superior no corpus brasileiro (15,59% em PT contra 11,59% em inglês). Esse dado atesta que o público lusófono expressa reações mais emotivas, enfáticas e afetivas (tanto positivas de apoio e exclamação quanto de forte contestação).
- **Taxa de Perguntas (Busca Cognitiva):** Os comentários em inglês exibem uma taxa ligeiramente superior de interrogações (16,24% em EN contra 15,08% em português). A maior busca por respostas aponta para uma audiência em inglês ligeiramente mais orientada a questionar detalhes de execução técnica dos criadores de IA ou as fontes de informação apresentadas.

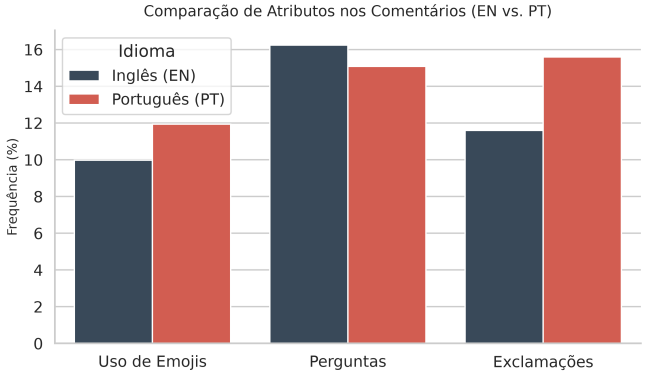


Fig. 9. Comparação de Atributos nos Comentários

3) Nível de Esforço Cognitivo nos Comentários: O nível de esforço cognitivo associado ao comentário atua como uma métrica de profundidade crítica das discussões espontâneas online. De acordo com a classificação estrutural proposta na metodologia (Figura 4.2):

- **Baixo Esforço:** 21% nos dois corpora (21,79% em EN, 20,72% em PT). Representa o público de consumo passivo que se manifesta de forma monossilábica ou com reações padronizadas (”bom”, ”ótimo vídeo”).
- **Médio Esforço:** 27-29% (27,08% em EN, 29,47% em PT).

- **Alto Esforço: 51,13% em inglês e 49,81% em português.**

O fato de aproximadamente metade de todos os comentários coletados (em ambos os idiomas) ser classificado como de **Alto Esforço** constitui um resultado de grande relevância acadêmica. Esse padrão sugere que a Inteligência Artificial não é recebida de maneira indiferente ou passiva pelo público em geral. Pelo contrário: trata-se de um tema de alto interesse cognitivo, que induz a audiência a redigir textos longos (mais de 20 palavras), articulando argumentos estruturados, relatando experiências profissionais e pessoais e ponderando sobre as implicações sociais da automação algorítmica.

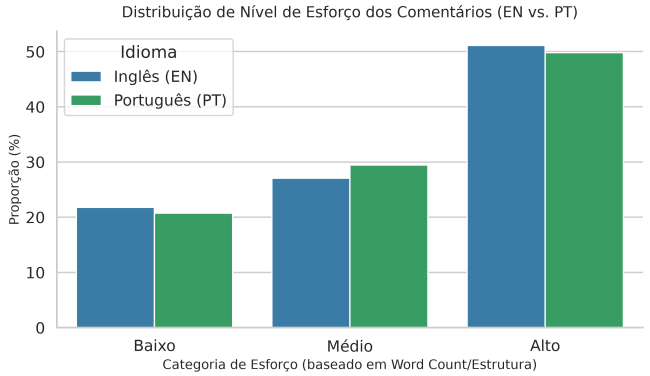


Fig. 10. Distribuição do Nível de Esforço dos Comentários

4) Discussão Integrada: Oferta vs. Demanda no Debate sobre IA: Ao contrapor os achados quantitativos das transcrições (oferta de conteúdo) às reações dos comentários (demanda do público), estabelece-se um rico panorama sociotécnico da percepção pública da IA:

1) **A Dialética da Eficiência vs. Preocupação Coletiva:** Os criadores de conteúdo estabelecem uma forte retórica de progresso instrumental ancorada no binômio *Realização-Autodireção* (exibindo e celebrando as potencialidades de ferramentas de IA). No entanto, o engajamento dos espectadores reconfigura esse enquadramento: discussões puramente instrumentalistas que enfocam apenas a ”eficiência computacional” geram reações de menor esforço, enquanto vídeos que abordam o conflito de valores (intersecções de IA com a Tradição, riscos de Segurança e dilemas de Universalismo) são os verdadeiros catalisadores de debates ativos de alto esforço cognitivo. O espectador engaja de forma crítica na contrapolarização dos valores.
2) **Assimetria Transcultural e a Estética Coloquial:** As diferenças psicolinguísticas evidenciam que, no Brasil, o debate público sobre inteligência artificial desenvolve-se sob uma esfera pública digital marcadamente mais calorosa, informal e interpessoal. Os criadores de conteúdo aproximam-se do público com elevados índices de Linguagem Informal (Média = 2,28%). A audiência, por sua vez, reage de forma coerente, manifestando uma taxa de expressividade visual (emojis = 11,94%) e ênfase emocional (exclamações = 15,59%) significativamente mais elevada que a audiência anglófona. O modelo sociotécnico brasileiro consolida-se assim em um formato de comunicação horizontal e expressivo, contrastando com o teor motivacional corporativo e ligeiramente mais formal/distanciado observado nas produções dos Estados Unidos.
3) **Maturidade Tecnológica Compartilhada:** Apesar das assimetrias socioeconômicas e geopolíticas evidentes de desenvolvimento entre o Norte e o Sul Global (assimetrias de *Compute Power*), os corpora mostram uma evolução temporal sincronizada. O ano de 2025 registrou uma convergência de maturidade tecnológica: criadores de ambos os idiomas passaram a focar substancialmente em eixos instrumentais de Realização, indicando a transição do software especulativo para a consolidação de ferramentas de desenvolvimento diárias, que impactam diretamente a economia local de ambos os países.

V. Considerações Finais

Este capítulo encerra este Trabalho de Conclusão de Curso sintetizando as principais conclusões e contribuições alcançadas no mapeamento sociotécnico da percepção pública sobre a Inteligência Artificial (IA) no YouTube. Inicialmente, recapitula-se o objetivo geral da pesquisa e apresentam-se as conclusões analíticas e metodológicas derivadas dos corpora do Brasil e dos Estados Unidos. Em seguida, discutem-se as limitações técnicas e práticas observadas durante a execução do projeto. Por fim, propõem-se caminhos de investigação e trabalhos futuros voltados ao avanço metodológico e analítico da Computação Social.

A. Conclusão Geral

Esta pesquisa teve como objetivo investigar a recepção pública da Inteligência Artificial a partir de comentários em mídias sociais, contrapondo o posicionamento e o engajamento afetivo da audiência (demanda) aos enquadramentos (*framings*) valorativos adotados pelos criadores de conteúdo (oferta) no YouTube. Ao analisar de forma transcultural os discursos e as reações em português (Brasil) e inglês (Estados Unidos), este trabalho expandiu os achados da fase inicial da pesquisa e propôs uma abordagem metodológica e empírica integrada no campo da Computação Social.

1) Síntese das Contribuições Teóricas e Metodológicas: O trabalho apresentou contribuições significativas em termos de arquitetura de Processamento de Linguagem Natural (PLN) e desenho de pesquisa sociotécnica em larga escala:

1) **Pipeline de PLN Escalável e Conformidade Ética:** Projetou-se e validou-se um pipeline de processamento de linguagem natural (PLN) otimizado para lidar com a natureza heterogênea e o alto teor de ruído semântico e ortográfico característicos das seções de comentários

de plataformas de compartilhamento de vídeo. Utilizando o framework de inferência de alto desempenho *vLLM* com técnicas de atenção otimizada (*PagedAttention*), realizou-se a paralelização massiva e a execução eficiente de modelos de linguagem autorregressivos (família Llama-3-8B-Instruct) parametrizados para tarefas de classificação e filtragem de spams. Esse pipeline automatizou a filtragem de *engagement baits* e a caracterização das métricas de escrita e níveis de esforço de recepção da audiência. Alinhado aos preceitos da Lei Geral de Proteção de Dados (LGPD) e às diretrizes de *Privacy by Design*, implementou-se um módulo de sanitização criptográfica e anonimização irreversível, expurgando metadados identificáveis (como *handles*, *usernames* e *channel IDs*) em tempo de execução.

2) **Modelagem de Valores via Transformers e Janela Deslizante:** Para decodificar os Valores Humanos de Schwartz nas falas contínuas presentes nas transcrições dos vídeos, utilizou-se o modelo baseado em *Transformers* **DeBERTa-v3** (finetunado no repositório `devnote5676/schwartz-values-classifier` [12]). A análise de textos longos foi otimizada por meio de um algoritmo de janela deslizante (*sliding window*) com tamanho de segmento fixado em 400 tokens e sobreposição estruturada (*overlap*) de 50 tokens, associado a um mapeamento dinâmico de offsets de caracteres, permitindo segmentar e classificar o conteúdo de forma precisa sem truncar palavras ou perder contexto semântico.
3) **Mapeamento Psicolinguístico Adaptado:** Desenvolveu-se um analisador psicolinguístico nativo baseado em dicionários de radicais (*stems*) em inglês e português, inspirado nas categorias clássicas do software LIWC 2015 [8], [9]. Para o corpus em português, o pipeline realizou o alinhamento semântico e a reconstrução de trechos originais a partir da tradução integrada, assegurando que os termos fossem avaliados diretamente em seu idioma nativo, mitigando vieses de tradução artificial.
4) **Mensuração do Nível de Esforço Cognitivo:** Formulou-se um modelo ordinal heurístico para mensurar o Nível de Esforço Cognitivo investido pelos usuários na formulação dos comentários. A modelagem classifica o engajamento textual em três níveis discretos (Baixo, Médio e Alto Esforço) com base na densidade de comprimento de caracteres, número absoluto de tokens informativos (excluindo *stopwords*) e na taxa de marcadores de expressividade pragmática e sintática (taxa de exclamação, interrogativos e marcadores pictográficos/emojis). Essa heurística operacionalizou o esforço cognitivo como uma variável latente indicativa de reflexão crítica, permitindo correlacionar a densidade informacional da recepção às variáveis valorativas da oferta.

2) Discussão Sintética dos Achados Empíricos: A análise integrada dos dados empíricos evidenciou dois macrofenômenos concernentes à dinâmica de mediação e recepção sociotécnica da Inteligência Artificial:

- **A Assimetria Dialética entre Oferta (Enquadramento Narrativo) e Demanda (Engajamento do Público):** Evidenciou-se um desalinhamento sistemático entre os polos motivacionais expressos na produção de conteúdo e aqueles que catalisam a interação crítica do público. Enquanto os criadores estruturam sua narrativa sob eixos de Auto-engrandecimento e Abertura à Mudança — concentrando-se nos valores de **Realização** (*Achievement*) e **Autodireção** (*Self-Direction*) para reportar otimização operacional e autonomia de desenvolvimento —, a resposta participativa do público é polarizada por tensões ligadas à Conservação e Autotranscendência. Conforme revelado pela correlação de Spearman, o engajamento ativo reflexivo (Alto Esforço Cognitivo na seção de comentários) exibe associação monótona positiva com os eixos de **Segurança** e **Universalismo** (debates éticos, regulação estatal e riscos distributivos de mercado). Em contrapartida, o consumo puramente passivo (mensurado por visualizações) é modulado de forma monótona positiva por apelos de **Hedonismo** e **Estimulação** (conteúdos demonstrativos de caráter recreativo ou especulações futuristas).
- **Divergências Transculturais e a Moderação do Contexto Nacional:** Sob a lente da teoria do *Compute North* versus *Compute South* [3] e do conceito de psicologia WEIRD (*Western, Educated, Industrialized, Rich, and Democratic*) [2], o teste de postos de Mann-Whitney U demonstrou que as discrepâncias discursivas e expressivas entre os corpora são estatisticamente significativas ($p < 0,001$) em todas as dimensões psicolinguísticas estudadas, permitindo a rejeição da hipótese nula H_0 de identidade de distribuições com elevado rigor científico:
- O corpus em **português (Brasil)** delineia uma esfera de recepção caracterizada por maior expressividade socioafetiva e horizontalidade discursiva. Apresenta maiores taxas medianas de *Linguagem Informal* (2,09%) e *Processos Biológicos* (marcadores conversacionais imperativos), além de manifestar expressividade pictográfica (emoji rate de 11,94%) e ênfase emotiva (exclamações em 15,59%). O debate sobre IA no Brasil é personalizado, com elevado apelo de *Processos Sociais* e *Preocupações Pessoais* (família, religião e impacto cotidiano imediato).
- O corpus em **inglês (Estados Unidos)** demonstra um enquadramento pragmático, instrumental e estruturado a partir da lógica de mercado e eficiência competitiva. Suas reações são focadas na dimensão de *Motivações* (metas acadêmicas, progresso comercial e soberania tecnológica corporativa) e em debates institucionais de regulação econômica (valor de *Poder* correlacionando-se positivamente com comentários ativos: $r_s = 0,1161$).

Esses achados corroboram a tese de que a percepção pública

de tecnologias emergentes não é uniforme globalmente; ao contrário, as plataformas de mídias sociais funcionam como repositórios sociotécnicos que refletem e refratam tanto as assimetrias materiais de infraestrutura de computação de cada país quanto os seus sistemas normativos de valores culturais.

B. Limitações Metodológicas e Técnicas

Não obstante o rigor metodológico e a robustez estatística do desenho experimental, identificam-se limitações intrínsecas às ferramentas analíticas e ao pipeline de coleta que circunscrevem a generalização dos achados:

1) **Rigidez Epistêmica de Heurísticas Baseadas em Dicionários (LIWC):** A abordagem baseada em dicionários lexicais estruturados de termos e radicais (*stems*) apresenta limitações severas na captação de dependências sintáticas de longo alcance, figuras de linguagem e nuances pragmáticas, tais como ironia, sarcasmo e duplo sentido. O método computa frequências de ocorrência isoladas de tokens e raízes morfológicas, negligenciando a semântica composicional das sentenças. Consequentemente, a classificação é suscetível a falsos positivos em categorias sensíveis (por exemplo, a codificação de verbos de percepção sensorial em português, como ”ver” e ”ouvir”, como indicadores de *Processos Biológicos*, quando exercem apenas a função de marcadores discursivos de atenção).
2) **Opacidade Amostral e Restrições Estatísticas das APIs de Plataformas:** O pipeline de extração de dados é severamente limitado pelas políticas de entrega e restrições de cotas da *YouTube Data API v3*. Essa dependência introduz vieses de amostragem sistemáticos: a API restringe o acesso retrospectivo a dados apagados, moderados ou editados por criadores e usuários antes do momento da coleta. Além disso, a impossibilidade de extração de dados demográficos diretos (gênero, faixa etária, localização geográfica precisa dos comentadores) devido a salvaguardas de privacidade limita a inclusão dessas covariáveis nos modelos explicativos de recepção tecnológica, gerando uma opacidade que restringe a validação empírica de recortes interseccionais.

C. Direções de Pesquisa e Trabalhos Futuros

Com o propósito de superar as limitações apontadas e estender os limites teóricos e empíricos estabelecidos neste estudo, propõem-se as seguintes linhas de investigação científica futura:

1) **Abordagem Composicional via Modelos de Linguagem de Grande Escala e Sentimento Baseado em Aspectos:** Recomenda-se superar a dependência de métodos léxico-heurísticos pela transição para pipelines fundamentados em representações semânticas profundas obtidas de modelos de linguagem autorregressivos de grande porte (como Llama-3-70B e Gemini 1.5 Pro) em regime de *zero-shot* ou *few-shot prompting* estruturado. Sugere-se, especificamente, o desenvolvimento de tarefas de Análise de Sentimento Baseada em Aspectos (*Aspect-Based Sentiment Analysis - ABSA*), permitindo discernir e classificar a valência afetiva do público direcionada a entidades e conceitos discretos (como regulação, privacidade, eficiência técnica e custos computacionais), mapeando o posicionamento em relação a alvos específicos do discurso de IA.
2) **Modelagem Dinâmica Temporal de Tópicos Semânticos:** Propõe-se a aplicação de modelos de tópicos neurais dinâmicos (como o *Dynamic BERTopic* com representações dinâmicas de embeddings contextuais temporais). Esta metodologia viabilizará a detecção de derivas semânticas latentes (*semantic drifts*) ao longo de uma linha temporal contínua, permitindo correlacionar alterações nos tópicos de interesse público com eventos externos relevantes (tais como marcos regulatórios internacionais ou lançamentos de modelos de fronteira).
3) **Formalização de Métricas de Acordo Inter-Anotadores em Holdout Sets:** Com o objetivo de atestar rigorosamente a validade interna do pipeline de classificação automática de posicionamento e sentimentos, recomenda-se a estruturação de um conjunto de teste independente (*holdout set*) anotado manualmente por múltiplos revisores humanos experts. A concordância inter-avaliadores deverá ser quantificada por métricas robustas de validação cruzada, como o Kappa de Fleiss ou o Alpha de Krippendorff, servindo como benchmark empírico para calibração, estimação de erro sistemático e mitigação de alucinações semânticas nos modelos de inferência automática.

REFERÊNCIAS

[1] P. G. Kelley et al., “Exciting, useful, worrying, futuristic: Public perception of artificial intelligence in 8 countries,” in *Proceedings of the AAAI/ACM Conference on AI, Ethics, and Society* (AIES ’21), 2021.

[2] B. Howell, “Weird? institutions and consumers’ perceptions of artificial intelligence in 31 countries,” *AI & SOCIETY*, pp. 1–23, 2025.

[3] V. Lehdonvirta, B. Wiik, and Z. Hawkins, “Compute north vs. compute south: The uneven possibilities of compute-based ai governance around the globe,” in *Proceedings of the AAAI/ACM Conference on AI, Ethics, and Society* (AIES ’24), 2024.

[4] G. Moreira, E. Bogucka, M. Constantinides, and D. Quercia, “The hall of ai fears and hopes: Comparing the views of ai influencers and those of members of the u.s. public through an interactive platform,” in *Proceedings of the CHI Conference on Human Factors in Computing Systems* (CHI ’25), 2025.

[5] B. Rieder, A. Matamoros-Fernández, and Ò. Coromina, “From ranking algorithms to ’ranking cultures’: Investigating the modulation of visibility in youtube search results,” *Convergence*, vol. 24, no. 1, pp. 50–68, 2018.

[6] M. Grootendorst, “BERTopic: Neural topic modeling with a class-based tf-idf procedure,” *arXiv preprint arXiv:2203.05794*, 2022.

[7] J. Libovický, R. Rosa, and A. Fraser, “On the language neutrality of pre-trained multilingual representations,” in *Findings of the Association for Computational Linguistics: EMNLP 2020*, 2020, pp. 1663–1674.

[8] J. W. Pennebaker, R. L. Boyd, K. Jordan, and K. Blackburn, “The Development and Psychometric Properties of LIWC2015,” Austin, TX: University of Texas at Austin, 2015.

[9] F. Carvalho et al., “Evaluating the Brazilian Portuguese Version of the 2015 LIWC Lexicon with Sentiment Analysis in Social Networks,” in *Proceedings of the VIII Brazilian Seminar on Social Network Analysis and Mining* (BraSNAM), 2019.

[10] S. Schwartz, “An Overview of the Schwartz Theory of Basic Values,” *Online Readings in Psychology and Culture*, vol. 2, no. 1, pp. 1–20, 2012.

[11] J. Devlin, M.-W. Chang, K. Lee, and K. Toutanova, “BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding,” in *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*, vol. 1, 2019, pp. 4171–4186.

[12] P. He, X. Liu, J. Gao, and J. Chen, “DeBERTa: Decoding-enhanced BERT with Disentangled Attention,” in *Proceedings of the International Conference on Learning Representations* (ICLR), 2021.

[13] A. Dias, R. Tanure, J. Almeida, H. Lima, and C. Ferreira, “Análise da percepção do uso de cigarros eletrônicos no Brasil por meio de comentários no YouTube,” in *Anais do Simpósio Brasileiro de Sistemas Multimídia e da Web* (WebMedia ’24), 2024.

[14] R. Ottoni, E. Cunha, G. Magno, P. Bernardina, W. Meira Jr., and V. Almeida, “Analyzing right-wing YouTube channels: Hate, violence and discrimination,” in *Proceedings of the 10th ACM Conference on Web Science* (WebSci ’18), 2018.

[15] K. Elmholdt, J. Nielsen, C. Florczak, R. Jurowetzki, and D. Hain, “The hopes and fears of artificial intelligence: a comparative computational discourse analysis,” *AI & SOCIETY*, pp. 1–18, 2025.