



Redes Complexas para Extração de Padrões em Análise de Temperamento em Redes Sociais

Pedro Henrique Marra Araújo ¹



<https://doi.org/10.36557/2009-3578.2025v11n2p2188-2201>

Artigo recebido em 26 de Julho e publicado em 6 de Setembro de 2025

ARTIGO ORIGINAL

RESUMO

Introdução: O temperamento, natureza geral do estado emocional de um indivíduo, é influenciado pelo uso de redes sociais, onde usuários exibem padrões de comportamento que podem formar comunidades. A análise desses padrões é crucial para entender a relação entre o ambiente digital e o bem-estar do usuário. **Objetivos:** Este trabalho visa analisar dados de comportamento de usuários do Instagram para extrair padrões e identificar comunidades semanticamente relevantes, correlacionando-os com os temperamentos dos usuários, avaliados pela ferramenta TEMPS-RIO. **Metodologia:** A partir de uma base de dados real, foi realizada uma análise estatística para selecionar características comportamentais relevantes. Utilizou-se uma métrica ponderada para construir uma rede complexa e o Algoritmo de Louvain para otimizar a detecção de comunidades. **Conclusão:** Os resultados demonstram que é possível inferir padrões e comportamentos comunitários a partir de dados descritivos de uso de redes sociais. O método proposto conseguiu agrupar usuários com temperamentos semelhantes, melhorando a interpretabilidade da rede e aumentando a modularidade, uma medida de qualidade da partição, em quase 50%, validando a hipótese de que comportamentos online refletem traços temperamentais subjacentes.

Palavras-chave: análise estatística, redes complexas, detecção de comunidades, extração de padrões



Complex Networks for Pattern Extraction in Temperament Analysis on Social Networks

ABSTRACT

Introduction: Temperament, the general nature of an individual's emotional state, is influenced by social media usage, where users exhibit behavioral patterns that can form communities. Analyzing these patterns is crucial for understanding the relationship between the digital environment and user well-being. **Objectives:** This study aims to analyze behavioral data from Instagram users to extract patterns and identify semantically relevant communities, correlating them with user temperaments assessed by the TEMPS-RIO tool. **Methodology:** Using a real-world dataset, a statistical analysis was conducted to select relevant behavioral features. A weighted metric was used to construct a complex network, and the Louvain Algorithm was applied to optimize community detection. **Conclusion:** The results demonstrate that it is possible to infer patterns and community behaviors from descriptive social media usage data. The proposed method successfully grouped users with similar temperaments, enhancing the network's interpretability and increasing modularity, a partition quality measure, by nearly 50%, thus validating the hypothesis that online behaviors reflect underlying temperamental traits.

Keywords: statistical analysis, complex networks, community detection, pattern extraction

Instituição afiliada – Faculdade de Computação, Universidade Federal de Uberlândia (FACOM-UFU), Uberlândia, MG, Brasil.

Autor correspondente: Pedro Henrique Marra Araújo pedro.marra@ufu.br

This work is licensed under a [Creative Commons Attribution 4.0 International License](https://creativecommons.org/licenses/by/4.0/).





INTRODUÇÃO

É inegável a influência das redes sociais na vida das pessoas, que, de acordo com estatísticas, representam mais da metade da população global e as utilizam diariamente (Statista, 2023). Desde o início da pandemia de COVID-19, o uso das redes sociais tornou-se ainda mais vital para o funcionamento da sociedade, com o contato social migrando massivamente para o ambiente virtual (Scabini et al., 2021). Este fenômeno intensificou o debate sobre o impacto das redes sociais na saúde mental, uma correlação já bem estabelecida na literatura muito antes da pandemia. Estudos como o de (Twenge et al., 2018) apontam um aumento de 33% nos sintomas depressivos entre adolescentes com o crescimento exponencial das redes sociais entre 2009 e 2015.

Nesse contexto, o monitoramento das redes sociais tem sido usado para o entendimento do temperamento dos usuários (Weismayer, Gunter e Onder, 2021), buscando relacionar o comportamento online com traços de personalidade. Trabalhos como o de (Martins, 2022) desenvolveram métodos computacionais para analisar postagens no Instagram e extrair o temperamento de usuários, utilizando ferramentas psicométricas validadas como o TEMPS-RIO (Woodruff et al., 2011). Enquanto esses estudos demonstraram sucesso em classificar dados e estabelecer correlações, a utilização de métodos com caráter mais visual e estrutural, como as redes complexas, permanece subexplorada.

Redes complexas, que são essencialmente grafos com estruturas topográficas não triviais, oferecem um framework poderoso para modelar sistemas de interações, como os que ocorrem em redes sociais (Metz et al., 2007). Elas permitem uma análise que vai além da classificação individual, focando nas propriedades relacionais e na formação de comunidades. A aplicabilidade das redes complexas já foi demonstrada em estudos como o de (Correia, Li e Rocha, 2016), que mapeou a relação entre menções a antidepressivos e palavras-chave associadas à saúde mental no Instagram.

Este trabalho busca preencher a lacuna existente ao aplicar a análise de redes complexas aos dados de usuários do Instagram, originalmente coletados e classificados por (Martins, 2022). O objetivo central é manipular essas informações para extrair padrões e inferir comportamentos comunitários, correlacionando-os com os



temperamentos dos usuários. A hipótese subjacente é que usuários com temperamentos semelhantes exibirão padrões de uso da rede social que permitem seu agrupamento em comunidades distintas e mensuráveis, revelando a estrutura coletiva subjacente ao comportamento individual.

METODOLOGIA

O desenvolvimento deste trabalho foi dividido em uma sequência de etapas metodológicas: (i) preparação e análise descritiva da base de dados; (ii) seleção estatística das características mais relevantes para a distinção de temperamentos; e (iii) construção de uma rede complexa e aplicação de um algoritmo de detecção de comunidades para otimizar sua estrutura.

Dataset e Pré-processamento

A base de dados utilizada, agregada por (Martins, 2022), é composta por informações de 91 usuários do Instagram ($n=91$). Para cada usuário, o dataset inclui métricas de comportamento (e.g., quantidade de postagens, média de curtidas, seguidores, horários de postagem) e um rótulo de temperamento inferido pelo questionário TEMPS-RIO (Woodruff et al., 2011).

Inicialmente, foi aplicado um filtro para remover outliers, excluindo usuários com valores que se desviavam em mais de cinco desvios-padrão (5σ) em qualquer uma das características. Este processo resultou na remoção de 3 usuários, consolidando uma base final de 88 indivíduos para análise ($n=88$). Os temperamentos foram classificados como: (A) ansioso, (C) ciclotímico, (D) depressivo, (H) hipertímico, (I) irritável e (W) preocupado. Em casos de empate na pontuação do questionário, os usuários receberam rótulos multimodais (e.g., CD para ciclotímico/depressivo). A distribuição final dos temperamentos na amostra é detalhada na Tabela 1.

Tabela 1 — Estratificação dos usuários da base de dados em análise de acordo com seus temperamentos avaliados.



Temperamento	D	ACDHIW	CD	I	CDI	DI	AD	HI	DH	C
Quantidade	41	27	6	4	3	3	1	1	1	1

Seleção Estatística de Características

Para evitar a "maldição da dimensionalidade" e construir a rede com base nos sinais comportamentais mais significativos, foi realizado um processo de seleção de características. Primeiramente, aplicou-se a Análise de Variância (ANOVA ou F-test) para identificar quais características apresentavam variâncias estatisticamente diferentes entre os grupos de temperamento, utilizando um nível de significância de $\alpha = 0.005$. A Tabela 2 apresenta um extrato das características que passaram nesse teste, ordenadas por seu p_{value} .

Tabela 2 — Características com diferença de variância estatisticamente significativa entre pares de temperamentos (resultados selecionados).

Característica (C)	Temperamento (A)	Temperamento (B)	p_{value}
Quantidade de postagens	CD	I	0.0036
Quantidade de postagens positivas	CD	I	0.0037
Quantidade com emoticon	CD	I	0.0043
Quantidade de postagens	ACDHIW	I	0.0067
Quantidade de postagens	D	I	0.0081
Proporção posts (madrugada)	CDI	D	0.0172
Quantidade de seguidos	D	DI	0.0217
Média de curtidas	ACDHIW	CD	0.0393
Média de curtidas	ACDHIW	D	0.0478

Em seguida, para eliminar redundâncias, foi realizada uma análise de correlação de Pearson (r) e Spearman (ρ) entre as características pré-selecionadas. A Tabela 3 mostra que algumas características são fortemente correlacionadas, como a quantidade



de postagens e a quantidade de postagens positivas ($r = 0.978$), justificando a remoção de uma delas.

Tabela 3 — Análise de correlação entre características relevantes selecionadas.

Par de Características	Pearson (r)	Spearman (ρ)
Proporção de postagens de fim de semana vs meio de semana	-1.000	-1.000
Quantidade de postagens vs Quantidade de postagens positivas	0.978	0.975
Quantidade de postagens positivas vs Quantidade com <i>emoticon</i>	0.863	0.823
Quantidade de seguidos vs Quantidade de seguidores	0.805	0.692
Média de curtidas vs Quantidade de seguidores	0.702	0.804

Com base na significância estatística, na representatividade na base de dados e na baixa redundância, o conjunto final de características escolhido para a construção da rede foi: $C = \{\text{média de curtidas, quantidade de postagens com emoticon, quantidade de postagens neutras, quantidade de postagens negativas}\}$.

Construção da Rede e Detecção de Comunidades

A rede complexa foi modelada como um grafo ponderado $G = (V, E)$, onde os vértices V são os 88 usuários e as arestas E representam a similaridade comportamental entre eles. O peso de cada aresta foi calculado por uma métrica personalizada, definida pela Equação 1.

$$P(x, y, C) = \sum_{c_i \in C} \frac{|c_i(x) - c_i(y)|}{|\sigma(c_i(x)) - \sigma(c_i(y))|^{\delta_{T(x), T(y)}}} \quad (1)$$

Nesta equação, x e y são usuários, $c_i(x)$ o valor da característica i para o usuário x , $\sigma(c_i(x))$ é o desvio padrão desta característica para o temperamento $T(x)$ do usuário e $\delta_{T(x), T(y)}$ é o Delta de Kronecker para identificar se os usuários possuem temperamentos iguais ou diferentes. A métrica funciona como uma distância de Manhattan ponderada, onde o denominador amplifica o peso das características que mais discriminam os temperamentos (ou seja, aquelas com maior diferença de desvio



padrão entre grupos).

Para identificar a estrutura de comunidades na rede, foi utilizado o Algoritmo de Louvain (Blondel et al., 2008). Este é um método heurístico que busca otimizar a modularidade (Q) da rede, uma métrica que quantifica a densidade de conexões dentro das comunidades em comparação com as conexões entre comunidades. Valores de Q entre 0.3 e 0.7 tipicamente indicam uma forte estrutura comunitária (Newman e Girvan, 2004).

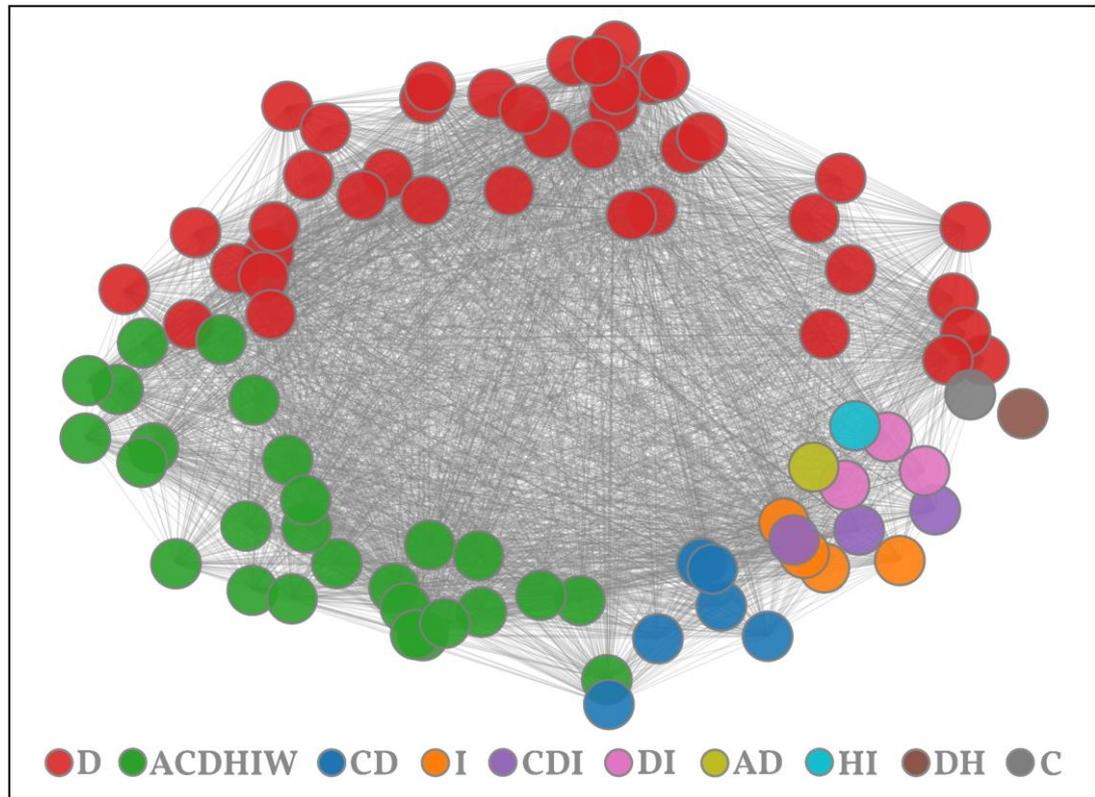
RESULTADOS E DISCUSSÃO

A análise dos resultados segue uma narrativa que parte da rede inicial, baseada na métrica proposta, até a rede final, otimizada pelo algoritmo de detecção de comunidades, demonstrando a melhoria na estrutura e na interpretabilidade.

Estrutura da Rede Preliminar

A rede inicial, G , foi construída utilizando a métrica da Equação 1 sobre o conjunto de características selecionado. O cálculo da modularidade para esta rede, considerando os 10 temperamentos originais como as comunidades, resultou em $Q \approx 0.32$. Embora este valor esteja no limiar inferior do que é considerado uma estrutura comunitária forte, ele é significativamente superior a zero, indicando que a métrica baseada em seleção estatística foi capaz de capturar uma organização não aleatória dos usuários. A Figura 1 ilustra a complexidade e a baixa interpretabilidade visual desta rede preliminar.

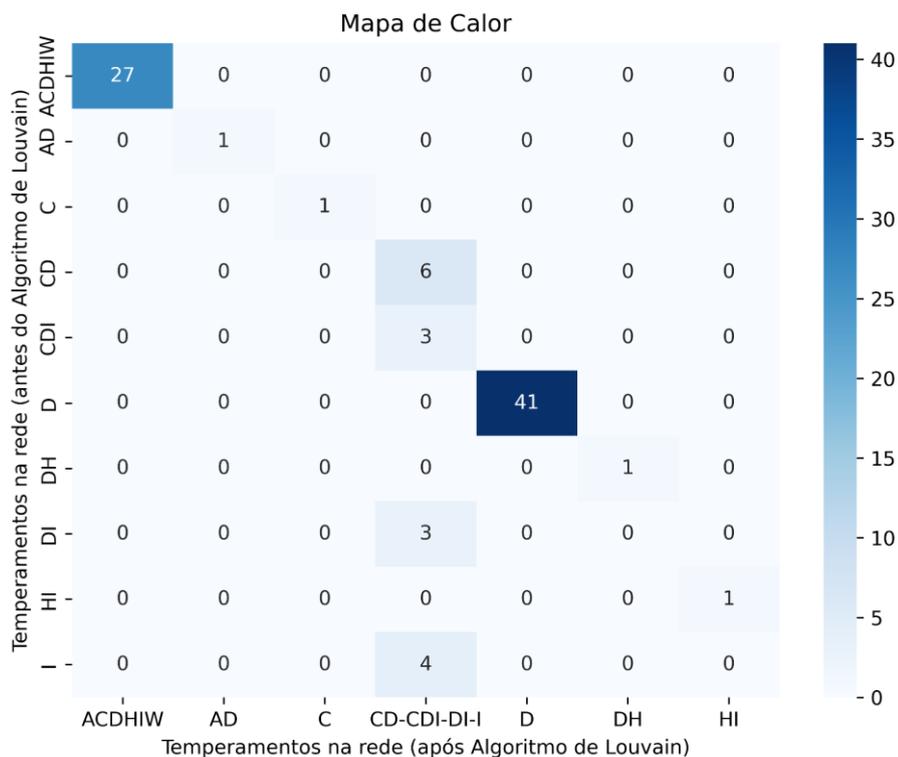
Figura 1 — Rede complexa preliminar (G) criada com a métrica proposta. A modularidade inicial é $Q \approx 0.32$.



Otimização de Comunidades com o Algoritmo de Louvain

A aplicação do Algoritmo de Louvain sobre a rede G resultou em uma nova partição dos usuários. O algoritmo, de forma agnóstica aos rótulos de temperamento, consolidou as 10 comunidades originais em 7 partições otimizadas. A Figura 2 mostra um mapa de calor que detalha esse agrupamento.

Figura 2 — Mapa de calor ilustrando o agrupamento dos 10 temperamentos originais (eixo y) nas 7 comunidades otimizadas pelo Algoritmo de Louvain (eixo x).



Notavelmente, o algoritmo agrupou temperamentos com sobreposição clínica e comportamental em uma única comunidade. Por exemplo, os temperamentos CD (ciclotímico/depressivo), CDI (ciclotímico/depressivo/irritável), DI (depressivo/irritável) e I (irritável) foram fundidos em um único cluster. Este resultado sugere uma validação computacional da proximidade psicológica entre esses perfis, uma vez que o algoritmo identificou sua semelhança com base unicamente em padrões de comportamento na rede social, sem qualquer conhecimento prévio de psicologia.

Análise da Estrutura da Rede Final

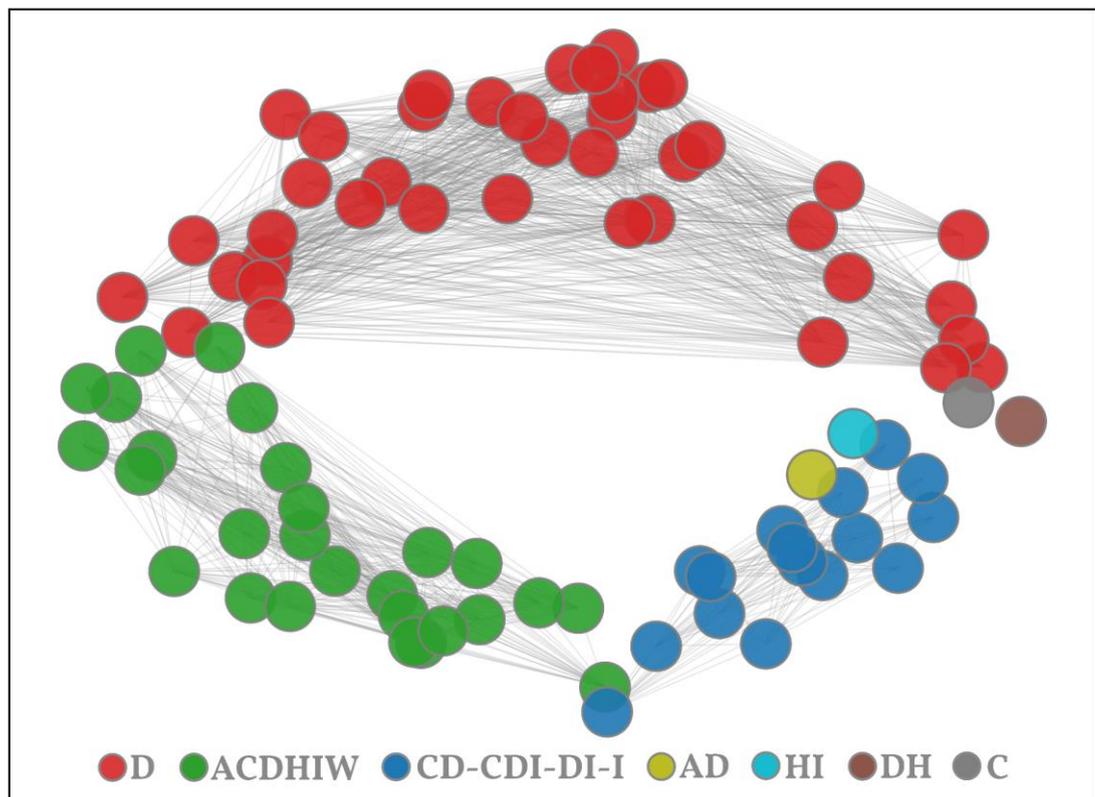
Com base nas partições encontradas pelo Algoritmo de Louvain, foi construída a rede final, G_L . Esta nova rede apresentou uma modularidade de $Q(G_L) \approx 0.474$, representando um aumento de aproximadamente 48% em relação à rede inicial. Este valor está solidamente dentro da faixa que indica uma estrutura comunitária robusta e bem definida.

A Figura 3 visualiza a rede G_L , onde a clareza da separação entre as comunidades



é evidente. A formação de grandes clusters bem definidos (em vermelho, verde e azul) confirma a hipótese central do estudo: o comportamento em redes sociais contém sinais suficientemente fortes para particionar usuários em grupos que se alinham com seus temperamentos subjacentes. A melhoria drástica na modularidade e na interpretabilidade visual valida a eficácia da metodologia proposta.

Figura 3 — Rede complexa otimizada (G_L) após a aplicação do Algoritmo de Louvain. A modularidade final é $Q(G_L) \approx 0.474$, evidenciando uma estrutura comunitária clara.



CONSIDERAÇÕES FINAIS

Este trabalho demonstrou a viabilidade de utilizar redes complexas para estruturar dados de usuários de redes sociais com base em seus temperamentos. A principal contribuição foi o desenvolvimento de uma metodologia que combina seleção estatística de características, uma métrica de similaridade personalizada e detecção de



comunidades para revelar padrões de comportamento coletivo. O resultado quantitativo mais significativo foi o aumento de quase 50% na modularidade da rede, transformando um grafo inicialmente denso em uma estrutura com comunidades claras e semanticamente coerentes.

O estudo validou a hipótese de que é possível inferir e modelar a afinidade entre usuários a partir de seus comportamentos no Instagram, de forma que os agrupamentos computacionais correspondem a perfis de temperamento psicologicamente relacionados. A fusão de temperamentos como depressivo, ciclotímico e irritável em uma única comunidade pelo algoritmo é uma forte evidência de que padrões de uso da plataforma refletem traços de personalidade subjacentes.

As limitações do estudo incluem o tamanho relativamente pequeno da amostra (88 usuários) e sua especificidade demográfica. Para trabalhos futuros, sugere-se a aplicação desta metodologia a bases de dados maiores e mais diversas. Além disso, a inclusão de outras características comportamentais, como a análise de comentários ou a proporção de seguidores verificados, poderia enriquecer o modelo e aumentar sua precisão. A exploração de outras métricas de qualidade de partição, como a NMI (Informação Mútua Normalizada), também se apresenta como uma via promissora para futuras investigações.

REFERÊNCIAS

BLONDEL, V. D. *et al.* Fast unfolding of communities in large networks. **Journal of Statistical Mechanics: Theory and Experiment**, v. 2008, n. 10, p. P10008, out. 2008. Disponível em: <https://iopscience.iop.org/article/10.1088/1742-5468/2008/10/P10008>. Acesso em: 4 set. 2025.

CORREIA, R. B.; LI, L.; ROCHA, L. M. Monitoring potential drug interactions and reactions via network analysis of instagram user timelines. *In: Biocomputing 2016: Proceedings of the Pacific Symposium*. [S.l.]: World Scientific, 2016. p. 492–503.

MARTINS, L. M. **Análises de publicações da rede social Instagram em contraste com o**



temperamento humano. 2022. Dissertação (Mestrado) – Universidade Federal de Uberlândia, Uberlândia, 2022.

METZ, J. *et al.* **Redes Complexas:** conceitos e aplicações. São Carlos: [s.n.], 2007.

NEWMAN, M. E. J.; GIRVAN, M. Finding and evaluating community structure in networks. **Physical Review E**, v. 69, n. 2, p. 026113, fev. 2004. Disponível em: <https://journals.aps.org/pre/abstract/10.1103/PhysRevE.69.026113>. Acesso em: 4 set. 2025.

SCABINI, L. F. *et al.* Social interaction layers in complex networks for the dynamical epidemic modeling of covid-19 in brazil. **Physica A: Statistical Mechanics and its Applications**, v. 564, p. 125498, 2021. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0378437120307962>. Acesso em: 4 set. 2025.

STATISTA. **Social Media User-Generated Content.** 2023. Disponível em: [COLE O LINK AQUI]. Acesso em: 4 set. 2025.

TWENGE, J. M. *et al.* Increases in depressive symptoms, suicide-related outcomes, and suicide rates among u.s. adolescents after 2010 and links to increased new media screen time. **Clinical Psychological Science**, v. 6, n. 1, p. 3–17, 2018. Disponível em: <https://www.statista.com/markets/424/topic/540/social-media-user-generated-content/>. Acesso em: 4 set. 2025.

WEISMAYER, C.; GUNTER, U.; ONDER, I. Temporal variability of emotions in social media posts. **Technological Forecasting and Social Change**, v. 167, p. 120699, 2021. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0040162521001311>. Acesso em: 4 set. 2025.

WOODRUFF, E. *et al.* Validation of the brazilian brief version of the temperament auto-questionnaire temps-a: The brief temps-rio de janeiro. **Journal of Affective Disorders**, v. 134, n. 1, p. 65–76, 2011. Disponível em:



<https://www.sciencedirect.com/science/article/pii/S0165032711000590>. Acesso em: 4 set. 2025.