

Automação da análise de sentimentos em textos de redes sociais - uma revisão qualitativa da literatura

Daniel N. Santos¹

¹Centro de Informática – Universidade Federal de Pernambuco (CIn - UFPE)
Av. Jorn. Aníbal Fernandes – s/n – Recife – PE – Brasil

dns2@cin.ufpe.br

Abstract. *The evolution in the perception of social networks beyond entertainment has led them to emerge as a major vehicle for the opinions sharing and personal expressions. In this context, sentiment analysis arises as a way to interpret these sentiments in an automated manner through computational processes. This work aims to explore the literature in order to understand the benefits derived from the application of sentiment analysis in its various contexts, analyzing the computational techniques employed and the challenges encountered, as well as discussing proposed approaches for future applications.*

Resumo. *A evolução na percepção das redes sociais para além do entretenimento a fez emergir como um grande vetor para a manifestação de opiniões e expressões pessoais. Deste modo, a análise de sentimentos surge como uma maneira de interpretar estes sentimentos de forma automatizada a partir de processos computacionais. Este trabalho visa explorar a literatura a fim de compreender os ganhos advindos da aplicação da análise de sentimentos em seus diversos contextos, analisando as técnicas computacionais empregadas e os desafios encontrados, além de abordar a proposta de abordagens em aplicações futuras.*

1. Introdução

As redes sociais têm passado por um processo de transformação em termos de valor social e cultural, evoluindo rapidamente de plataformas voltadas majoritariamente à interação informal e entretenimento para se tornarem espaços consolidados de expressão pública e coletiva de opiniões e sentimentos. Em plataformas como o X, Facebook e Instagram, por exemplo, milhões de usuários expressam diariamente suas reflexões e reações emocionais sobre uma ampla variedade de tópicos, desde eventos cotidianos até questões sociais complexas. Tal fenômeno acaba por gerar um imenso volume de dados de maneira espontânea, representando uma grande oportunidade para a exploração e desenvolvimento de métodos computacionais que possibilitem a interpretação, classificação e compreensão de informações subjetivas e emocionais de maneira automática e em larga escala.

Neste cenário, a análise de sentimentos (do inglês *sentiment analysis* ou *opinion mining*) vem se destacando como uma das subáreas mais promissoras e amplamente estudadas do processamento de linguagem natural (do inglês *Natural Language Processing* ou *NLP*). Seu objetivo principal reside na identificação, extração e classificação de opiniões, sentimentos e atitudes expressas em todo tipo de mídia, como textos, áudios e vídeos,

oferecendo *insights* valiosos que podem ser aplicados em diversos setores da sociedade, como saúde e entidades governamentais [Hasib et al. 2023, Yousaf et al. 2021].

Um dos contextos mais claros para as vantagens advindas da utilização da análise de sentimentos ocorre sob a ótica do setor empresarial. Empresas dependem cada vez mais das redes sociais para promover influência sobre os seus clientes e estas, por sua vez, têm o poder de reforçar ou prejudicar a imagem das marcas, a depender do tom de suas publicações [Liu et al. 2020]. Por mais que estas empresas possam tentar mitigar os impactos de uma relação negativa com seus clientes através da análise de sentimentos aplicada dentro de suas plataformas proprietárias [Kumar et al. 2024], observa-se um crescimento contínuo no número de usuários que realizam análises e avaliações de produtos e serviços diretamente nas redes sociais. No caso das empresas de *e-commerce*, por exemplo, não é interessante que os *feedbacks* negativos extrapolem os limites de seus canais de venda, pois acabam ganhando visibilidade global e, ao passo que as avaliações positivas funcionam quase como propaganda gratuita, os comentários negativos podem gerar o afastamento de potenciais clientes. Por este motivo, várias empresas passam a fazer uso de sistemas que auxiliam no relacionamento com o cliente, com o objetivo de analisar o que os usuários de redes sociais têm falado a seu respeito, utilizando a estratégia conhecida como *social listening* [Westermann and Forthmann 2021]. Sendo assim, a extração e mensuração dos sentimentos dos usuários torna-se fundamental para as organizações, não apenas para realizar melhorias no relacionamento com o cliente, mas também para que possam providenciar estratégias assertivas de marketing e posicionamento de marca, justificando que as mesmas busquem cada vez mais pela área [Behera et al. 2021].

O ambiente acadêmico também tem demonstrado vasto interesse pela análise de sentimentos, seja impulsionado pela demanda crescente do mercado por soluções automatizadas e escaláveis, ou ainda pela rápida evolução das técnicas de aprendizado de máquina (do inglês *Machine Learning* ou *ML*), como as arquiteturas baseadas em redes neurais profundas e *transformers*. Os avanços recentes em *machine learning*, bem como modelos contextuais pré-treinados, vêm proporcionando melhorias significativas na eficiência e acurácia da análise de sentimentos. Tais métodos contribuem de forma direta para o sucesso da área, permitindo combinações cada vez mais sofisticadas, como a utilização de *embeddings* contextuais, resultando em abordagens robustas, adaptáveis e com desempenho cada vez melhor [Tan et al. 2022].

Tendo em vista este cenário, o presente trabalho visa fornecer uma visão abrangente e detalhada a respeito do estado da arte referente ao processo de automação na classificação de sentimentos em mídias textuais provenientes de redes sociais, detalhando os contextos de utilização e principais tecnologias utilizadas no processo, juntamente com suas vantagens e desvantagens. O material também conta com análise crítica a respeito das tendências observadas, apontando limitações e sugerindo potenciais direcionamentos para pesquisas futuras. Através de todo este arcabouço, visa-se a contribuição para com o avanço teórico e prático deste importante campo de estudo.

2. Metodologia

O presente estudo tomou como base a análise de artigos científicos com o objetivo de observar quais métodos computacionais têm sido utilizados para a análise de sentimentos em textos provenientes de redes sociais, quais são suas principais características e também

aplicações. Dentro deste escopo, também torna-se relevante entender características a respeito dos métodos em questão, como:

- Quais são os métodos mais comuns neste processo?
- Quais são as métricas utilizadas para avaliá-los?
- Em quais contextos práticos eles são utilizados?
- Quais são limitações ou desafios apontados pela literatura?

Com este propósito em mente, foram adotadas as diretrizes PRISMA (do inglês *Preferred Reporting Items for Systematic Reviews and Meta-Analyses*) [Moher et al. 2010], envolvendo a definição de descritores, utilização de critérios de inclusão/exclusão e seleção sistemática dos trabalhos relacionados. Desta maneira, o processo se deu através das etapas detalhadas a seguir.

2.1. Busca

Para a identificação dos estudos relevantes, foi realizada uma busca estruturada através da base de dados *Scopus*, selecionada pela sua concentração de artigos de diferentes bases, centralizando a busca de maneira condizente e tornando o processo, de forma geral, mais ágil. A etapa foi realizada através de um processo conhecido como busca booleana (do inglês *Boolean Search*), utilizando palavras-chave e termos em inglês relacionados ao contexto, juntamente com operadores como *AND* e *OR*, criando relações entre os termos e permitindo uma busca com maior grau de especificidade. A seguir apresenta-se a *string* de busca utilizada:

(“*sentiment analysis*”*OR* “*opinion mining*”*OR* “*emotion detection*”) *AND* (“*machine learning*”*OR* “*deep learning*”*OR* “*lexicon-based*”) *AND* (“*social media*”*OR* “*social network*”) *AND* (“*text*”*OR* “*message*”)

A construção da *string* teve como objetivo abranger os principais vocábulos utilizados na análise de sentimentos com foco no conteúdo textual proveniente de redes sociais. Foram incluídos termos como *sentiment analysis*, *opinion mining* e *emotion detection* com o intuito de cobrir as diferentes denominações que o campo de estudo possui. Os termos *machine learning*, *deep learning* e *lexicon-based*, por sua vez, foram incorporados para especificar os métodos de aplicação considerados na análise, sendo eles também os mais comuns, como analisaremos adiante. A adição de termos como *social media* e *social network* visa delimitar o escopo às plataformas digitais de interação social, enquanto os termos *text* e *message* visam a restrição dos resultados a conteúdos textuais, principal objeto de análise neste estudo. De forma geral, a *string* foi arquitetada para maximizar a abrangência temática e, ao mesmo tempo, manter a relevância dos resultados recuperados para as perguntas de pesquisa.

A busca realizada resultou em um total de 2.319 publicações, as quais ainda seriam submetidas a diversos processos de filtragem até a formação da amostra final que viria a ser analisada de maneira minuciosa, como abordaremos adiante.

2.2. Critérios

Para assegurar a relevância, qualidade e alinhamento dos trabalhos aos objetivos deste estudo, foram definidos critérios claros e objetivos para a inclusão e exclusão dos resultados obtidos no processo de busca. Tais critérios permitiram delimitar o escopo da pesquisa,

filtrar resultados não pertinentes e garantir uma maior consistência à análise dos dados extraídos.

Como critérios de inclusão, foram considerados apenas os resultados pertencentes ao intervalo de cinco anos imediatamente anteriores à realização do presente trabalho, ou seja, publicações realizadas entre os anos de 2020 e 2024. O tipo de publicação também representou um fator importante para a inclusão, restringindo a seleção às revisões de literatura e artigos revisados por pares, visando uma maior confiabilidade e o mapeamento do estado da arte. Além destes, outros fatores fundamentais para a inclusão compreendem:

- **Área temática:** Considerou-se apenas os artigos sob o escopo da Ciência da Computação, com a intenção de obter uma visão detalhada a respeito das aplicações e revisões desenvolvidas na área, visto que ela é o ponto formador dos casos de uso em outras áreas.
- **Contexto:** Foram incluídos apenas os estudos cuja aplicação das técnicas de análise de sentimentos se voltam exclusivamente para redes sociais e seu conteúdo textual, como postagens e comentários.

A não satisfação de qualquer critério de inclusão estabelecido implica imediatamente na exclusão dos respectivos trabalhos. No entanto, os critérios de exclusão se estendem ainda ao idioma da publicação, onde um fator determinante é a escrita em inglês, e o estágio da publicação, sendo este último um ponto de atenção pois a plataforma *Scopus* lista trabalhos que ainda estão em processo de revisão, os quais não foram considerados. Deste modo, a etapa corrente resultou em um total de 693 publicações.

As publicações resultantes desta etapa constituíram a base para o processo de bibliometria, a qual foi realizada a partir do emprego da biblioteca *Bibliometrix*, ferramenta robusta e amplamente utilizada para a realização de análises bibliométricas, permitindo a extração, tratamento e visualização de dados científicos provenientes de diversas bases de dados acadêmicos [Aria and Cuccurullo 2017]. Vale salientar ainda que este conjunto não representa a totalidade de publicações analisadas de maneira aprofundada, de modo a responder às perguntas que guiam o presente trabalho, isso porque estas ainda viriam a ser definidas através de um processo de seleção, o qual é detalhado a seguir.

2.3. Seleção

Após a aplicação dos critérios de inclusão e exclusão, foi conduzida a seleção das publicações que viriam a ser, de fato, analisadas em detalhes. As 693 publicações foram submetidas a um processo de ordenação de acordo com o *Methodi Ordinatio*, método responsável por realizar a atribuição de pontuações aos trabalhos com base em aspectos bem definidos como o ano de publicação, fator de impacto e quantidade de citações, sendo bastante útil no auxílio à seleção de materiais científicos [Pagani et al. 2015].

Mínimo	1º quartil	2º quartil	3º quartil	Máximo
10,00	16,62	24,00	43,65	871,83

Tabela 1. Métricas de distribuição de pontuação

A aplicação do *Methodi Ordinatio* possibilitou a observação de aspectos fundamentais relacionados à distribuição de pontuações entre as publicações restantes. Quando

analisamos a figura 1 podemos perceber uma forte assimetria à direita, visto que a maior parte do material atingiu pontuações inferiores a 100 e, de maneira análoga, são poucos os artigos que pontuaram acima dos 200. Podemos ser ainda mais exatos em termos de valores ao afirmar que 75% dos trabalhos obtiveram pontuação menor que 43,65, conforme mostrado na tabela 1. A disparidade entre as pontuações observadas e sua distribuição levou à condução de uma revisão qualitativa da literatura, a partir da avaliação dos trabalhos mais relevantes disponíveis.

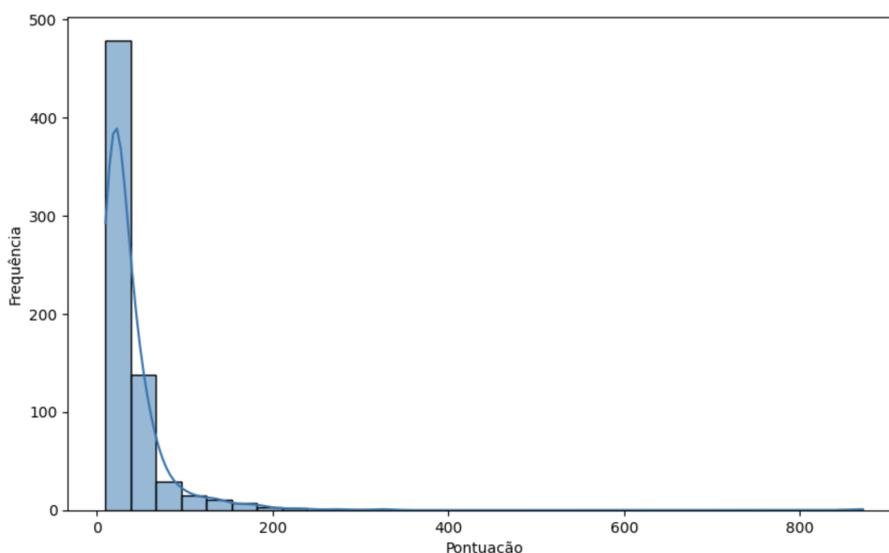


Figura 1. Distribuição de pontuações de acordo com o *Methodi Ordinatio*

Neste cenário, foram selecionados apenas os trabalhos enquadrados entre os 25% mais bem avaliados, isto é, aqueles com pontuação acima dos 43,65. Este último filtro resultou no total de 173 artigos, os quais constituem a amostra que passará pelo processo de análise refinada.

2.4. Análise

Uma vez selecionadas as publicações, seguiu-se a análise minuciosa das mesmas, com a finalidade de entender os principais aspectos abordados e sua contribuição para a literatura de forma geral, metodologia utilizada, processos pré e pós aplicação da análise de sentimentos, finalidade da utilização, reprodutividade dos resultados, clareza, desafios enfrentados e pontos de melhoria. Tal análise foi conduzida com o intuito de centralizar as informações a serem abordadas, servindo como guia para os pontos sobre os quais iremos nos debruçar na revisão técnica da bibliografia e análise crítica, ambas apresentadas mais adiante no presente trabalho.

Com relação aos aspectos técnicos, o foco da análise foi direcionado às fontes de dados utilizadas, o nível de detalhes do processo de treinamento, quando utilizando modelos de aprendizagem de máquina, ou ainda desenvolvimento e aplicação de algoritmos puramente léxicos. Também foram analisadas as argumentações técnicas e teóricas dos autores para justificar a adoção dos modelos, assim como as métricas quantitativas e qualitativas utilizadas para validar os resultados obtidos.

O caráter qualitativo e metodológico da análise buscou a identificação não apenas de padrões recorrentes nas abordagens técnicas descritas, mas também das diferenças significativas e lacunas relevantes, permitindo uma melhor compreensão a respeito de como cada trabalho contribui para o avanço da literatura, facilitando o mapeamento das tendências e destacando áreas ainda carentes de exploração ou aperfeiçoamento.

Para fins de clareza e maior entendimento do processo metodológico como um todo, a figura 2 traz uma síntese dos passos abordados anteriormente.

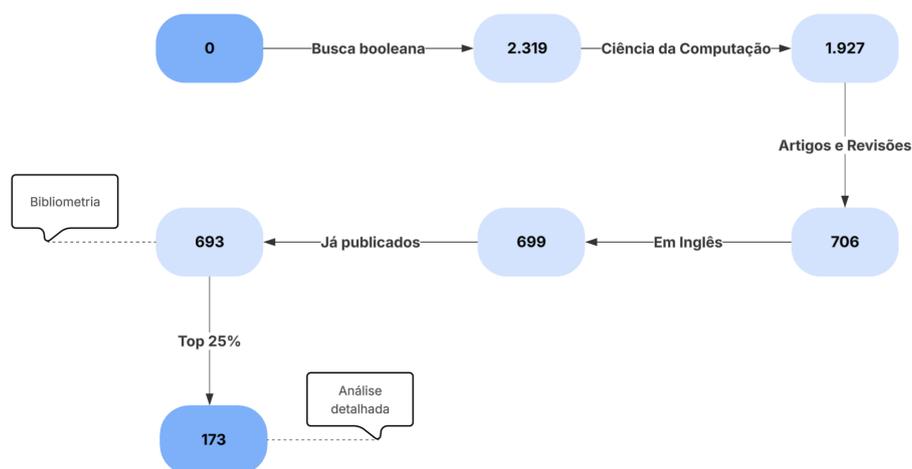


Figura 2. Processo metodológico

3. Revisão da literatura

Esta seção apresenta-se subdividida em duas partes centrais, sendo a primeira focada em disponibilizar uma visão a respeito da bibliometria em geral, elucidando pontos como a evolução na quantidade de publicações, além dos países e autores mais relevantes para a área de estudo. A segunda parte, por sua vez, debruça-se especificamente sobre a revisão dos trabalhos selecionados para a análise de acordo com o caráter qualitativo anteriormente explicitado, visando compreender, de forma aprofundada, os aspectos que norteiam o presente estudo.

3.1. Visão geral

Apesar da ocorrência de uma pequena queda, os estudos relacionados a aplicações de análises de sentimentos voltadas ao contexto de redes sociais têm apresentado um crescimento de 21% ao ano, o que pode ser observado na figura 3. São diversos trabalhos publicados em centenas de periódicos, dentre os quais a tabela 3 destaca os cinco mais populares. Tais fatos evidenciam um enorme crescimento da área em termos de interesse e relevância, o que é dado por uma série de fatores, entre eles o seu alto impacto no que se refere ao processo de tomadas de decisão estratégicas [Tan et al. 2022].

Dado este contexto, torna-se significativa a compreensão a respeito dos principais agentes responsáveis pela impulsão e evolução da área. Ao analisar a figura 4 podemos perceber que os países asiáticos apresentam grande dominância em se tratando dos países com mais trabalhos direcionados à temática, concentrando cerca de 34% das publicações com relação aos demais que figuram entre os dez mais influentes. Dentre estes países,

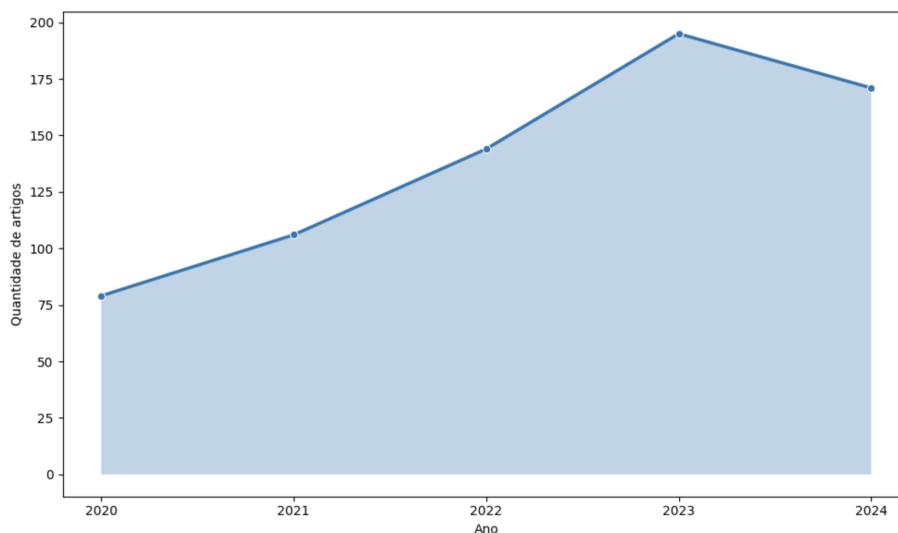


Figura 3. Evolução da quantidade de publicações ao longo dos anos

podemos destacar especialmente a Índia e a China que, além de serem os países com maior número de publicações, também são os mais citados na literatura especializada, como mostrado na figura 5, indicando também uma maior qualidade de seus trabalhos. Vale ainda ressaltar que não necessariamente uma maior quantidade de publicações está relacionada com um maior número de citações, bastando observar o caso da Arábia Saudita, que é o terceiro país com mais trabalhos publicados, mas não figura entre os dez com mais referências.

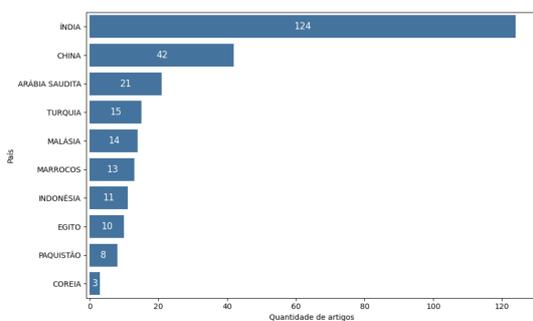


Figura 4. Quantidade de publicações por país

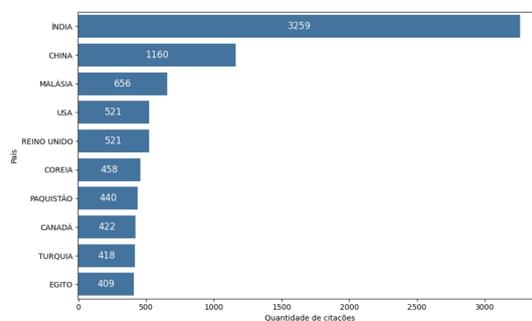


Figura 5. Quantidade de citações por país

De maneira análoga, também notamos uma alta relevância dos países asiáticos quando se trata de seus autores, visto que é deste mesmo continente que vêm os principais contribuintes para a análise de sentimentos sob contexto específico abordado neste estudo. Se tomarmos como base as informações da tabela 2, perceberemos que, dentre os cinco principais contribuintes, quatro representam instituições asiáticas. Em termos de quantidade de trabalhos a taxa permanece praticamente a mesma, com estes autores contribuindo com cerca de 82% das publicações, as quais permeiam contextos como a satisfação de clientes com serviços médicos, sustentabilidade urbana e conflitos geopolíticos, demonstrando alta flexibilidade de aplicação [Usman et al. 2024, Hamza et al. 2024, Lee et al. 2022a].

Autor	País	Publicações
ASHRAF I	Coréia do Sul	7
RUSTAM F	Paquistão	6
KUMAR S	Índia	5
LEE E	Estados Unidos	5
MOTWAKEL A	Arábia Saudita	5

Tabela 2. Principais autores

Periódico	Publicações
IEEE Access	53
IJACSA	30
Applied Sciences (Switzerland)	28
Multimedia Tools and Applications	24
JATIT	17

Tabela 3. Principais periódicos

3.2. Imersão teórica

A diversidade de cenários aplicáveis também pode ser percebida ao refinar a análise a partir da observação dos trabalhos mais relevantes, o que apresenta-se como um fator fundamental para a enorme atenção que a área tem recebido, evidenciando um enorme potencial sobre os mais variados contextos. É possível encontrar a análise de sentimentos sendo utilizada na detecção de notícias falsas com relação ao ambiente político e descobertas científicas, o que se torna possível pelo fato de seus propagantes utilizarem táticas textuais para fomentar emoções nos leitores, de modo que impulsionem a divulgação do conteúdo e, conseqüentemente, atinjam um maior número de pessoas [Mishra et al. 2022]. A compreensão sobre os sentimentos também se mostra útil para entidades governamentais, uma vez que podem se valer dela para o desenvolvimento de políticas sociais, além de possibilitar uma maior compreensão a respeito da percepção da população com relação a temas sensíveis, como é o caso da vacinação [Yousaf et al. 2021, Qorib et al. 2023]. Para além dos casos de uso já mencionados, a tabela 4 destaca alguns outros encontrados na literatura.

Publicação	Caso de uso
[Yousaf et al. 2021]	Reconhecimento de emoções
[Alattar and Shaalan 2021]	Razões para alteração do sentimento
[Hasib et al. 2023]	Detecção de depressão
[Ahmad et al. 2021]	Análise de personalidade
[Sufi and Khalil 2024]	Detecção de desastres naturais
[Lee et al. 2022b]	Detecção de atos racistas
[Aygun et al. 2022]	Análise de opinião pública
[Parekh et al. 2022]	Análise de mercado financeiro

Tabela 4. Casos de uso da análise de sentimentos

O fato de ser multidisciplinar, por sua vez, não impede que a área tenha um contexto de destaque, o qual é atribuído ao setor empresarial, sendo bastante comum encontrar casos onde as empresas se utilizam destas análises para obter uma visão mais ampla a respeito de suas performances em termos de alcance, popularidade e engajamento nas redes sociais [Kaur and Sharma 2023]. A análise destes tópicos ajuda não apenas na obtenção de uma visão geral a respeito de sua reputação entre os usuários [Liu et al. 2020], mas também em tomadas de decisão estratégicas, uma vez que a empresa pode atuar no desenvolvimento de melhorias dos serviços prestados e relações com seus clientes, servindo também como vantagem competitiva sobre os concorrentes [Kaur and Sharma 2023, Aljedaani et al. 2022].

Para uma utilização assertiva dos métodos de análise, e a conseqüente obtenção dos seus benefícios, torna-se necessário entender a forma como estes sentimentos são

retratados em seus casos de uso. A maioria das aplicações representa os sentimentos através de polaridades, distinguindo-as entre positiva, negativa e neutra [Talaat 2023]. No entanto, a literatura ainda aponta que este processo de classificação por polaridades pode ocorrer em diferentes níveis de especificidade, gerando uma nova subdivisão [Wankhade et al. 2022]. Com relação a estes subníveis de classificação, a literatura destaca:

- **Nível de documento:** Considera o texto como uma unidade completa e atribui a ele uma única polaridade (positiva, negativa ou neutra).
- **Nível de sentença:** Cada frase é analisada isoladamente com o objetivo de identificar seu sentimento predominante.
- **Nível de frase:** Foca em expressões específicas dentro das sentenças, geralmente formadas por palavras com carga opinativa, como é o caso dos adjetivos.
- **Nível de aspecto:** Identifica diferentes elementos mencionados em uma sentença e atribui uma polaridade a cada um deles separadamente.

Dentre os níveis acima referidos, é possível notar que o nível de aspecto vem ganhando mais destaque por uma série de fatores, a exemplo do fato de que, em muitos casos, os resultados baseados em polaridades genéricas não apresentam grande contribuição para análises aprofundadas, dado que um mesmo texto pode se referir a vários aspectos e possuir sentimentos distintos para cada um deles [Tao and Fang 2020]. Neste sentido, o foco da análise a nível de aspecto apresenta-se como uma solução ideal, uma vez que considera todos os tópicos relevantes do texto isoladamente, atribuindo sentimentos a cada um deles de forma independente. A literatura especializada mostra a possibilidade de desenvolvimento de aplicações sob este escopo, como a identificação de sentimentos relacionados a tópicos emergentes repercutidos nas redes sociais, sendo útil para a identificação de novas tendências e temas relevantes [Pathak et al. 2021].

O grande impacto estratégico, além das demais características abordadas até aqui, acabam por tornar a análise de sentimentos uma das sub-áreas mais importantes do processamento de linguagem natural [Tao and Fang 2020]. Através da figura 6 é possível perceber a forte relação da análise de sentimentos com métodos computacionais amplamente empregados pela *NLP*, como *machine learning* e *deep learning*. No entanto, ao mesmo tempo em que estas técnicas se apresentam como tendência nas aplicações mais robustas, é importante pontuar que elas coexistem com estratégias mais simples, como os algoritmos puramente léxicos. A distinção entre as abordagens é dada da seguinte maneira:

- **Abordagem léxica:** Se baseia em *lexicons*, listas pré-definidas de palavras com polaridades previamente associadas, utilizando regras semânticas e heurísticas linguísticas para determinar o sentimento do texto [Gupta et al. 2021, Berka 2020]. Esta estratégia é capaz de levar a resultados satisfatórios em domínios específicos, mas geralmente necessita de um grande esforço manual para a criação das listas, ainda mais quando o idioma ou contexto abordado não dispõem de material prévio [Xu et al. 2021, Bagherzadeh et al. 2021]. Tais características possibilitam uma implementação simples, mas a própria natureza da aplicação compromete sua escalabilidade.
- **Machine Learning & Deep Learning:** Envolvem o treinamento supervisionado ou semi-supervisionado de modelos computacionais capazes de aprender padrões

geral, este processo pode ser subprocessos como:

- **Uniformização do texto:** Responsável por converter todas as letras para uma única caixa. Geralmente o formato escolhido é a caixa baixa, convertendo em minúsculas todas as letras [Pimpalkar and R 2022, Talaat 2023, Yousaf et al. 2021].
- **Remoção de partes desnecessárias:** Constituído pela remoção de palavras como preposições, pronomes e conjunções, conhecidas como *stopwords*, o que se dá pelo fato de estas palavras não agregam relevância para as aplicações [Behera et al. 2021]. Além destas palavras, surge a necessidade de tratar outros tipos estruturas inerentes às redes sociais, a exemplo das *hashtags*, *links* ou até mesmo *emojis* [Aygün et al. 2022, Sunitha et al. 2022, Alattar and Shaalan 2021].
- **Criação de dicionários:** Em alguns casos pode ser necessário manter termos específicos ou emojis utilizados com muita frequência. Neste cenário, as soluções exigem a criação de dicionários customizados específicos para o contexto, levando em consideração os dados identificados como necessários para a aplicação [Aygün et al. 2022, Sunitha et al. 2022].
- **Tokenização:** Refere-se à quebra do texto em partes menores, conhecidas como *tokens*. Estes *tokens* podem ser palavras, pontuações ou até frases a depender da aplicação. Ao aplicar este processo, os métodos de análise são capazes de manipular as partes do texto de forma independente e encontrar relações entre termos, facilitando a interpretabilidade computacional [Iwendi et al. 2022].
- **Lematização:** Transformação de uma palavra em sua palavra base, conhecida como lema, a exemplo das palavras "correr" e "correu" que podem ser reduzidas para a palavra "corre", processo importante para que ocorra a centralização do significado em uma única estrutura [Behera et al. 2021].

3.2.2. Extração e representação de características

Em se tratando da extração e representação de características linguísticas, os métodos tradicionais baseados em representações vetoriais de frequência ainda são utilizados como ponto de partida ou para fins comparativos, especialmente pela simplicidade e interpretabilidade que oferecem. Dentre esses métodos, destacam-se:

- **Term Frequency–Inverse Document Frequency (TF-IDF):** Caracterizado pela realização de ponderações entre as palavras, levando em consideração sua frequência dentro de um texto em particular e também de forma geral entre todos os textos disponíveis [Salton and Buckley 1988]. Em seguida, são consideradas como mais relevantes as palavras que aparecem frequentemente em textos específicos, mas que são raras no contexto geral, destacando a especificidade da palavra e tornando o método útil no processo de identificação de palavras-chave [Yousaf et al. 2021].
- **Bag-of-Words (BOW):** Realiza a conversão dos textos em vetores numéricos baseados apenas na frequência das palavras, não levando em consideração características como ordem ou estrutura sintática das sentenças [Talaat 2023]. Cada posição do vetor representa uma palavra específica, com o valor correspondendo à frequência dessa palavra no texto, apresentando simplicidade computacional e

eficácia no processo de classificação [Lee et al. 2022b], sendo utilizado em conjunto com métodos de *machine learning* clássicos como *baseline* para avaliação de modelos mais complexos [Molero et al. 2023].

- **N-grams:** Considera sequências contíguas de n palavras como uma única unidade de análise, a exemplo dos bigramas ou trigramas [Shannon 1948, Tiwari et al. 2023]. Em contraste com o *BOW*, os *n-grams* são capazes de fornecer representações parciais da estrutura linguística, possibilitando uma melhor captura na relação entre as palavras e auxiliando o modelo em processos como o reconhecimento de padrões específicos e identificação do contexto em que a palavra está inserida [Ahmad et al. 2021].

De uma forma geral, os métodos de extração baseados em frequência não são capazes de capturar contextos semânticos [Pimpalkar and R 2022] e também podem impactar negativamente o modelo através da alta dimensionalidade decorrente de vocábulos extensos [Omuya et al. 2023]. Estes motivos contribuem para uma crescente utilização de técnicas baseadas em *embeddings* distribuídos, devido à sua capacidade de preservar relações semânticas e contextuais entre as palavras. As técnicas mais utilizadas deste escopo incluem:

- **Global Vector (GloVe):** Combina as características dos métodos baseados em frequência global e local, criando representações vetoriais eficientes das palavras com base em suas distribuições conjuntas entre as bases de texto [Pennington et al. 2014]. Devido a esta característica, ele pode ser utilizado para alimentar modelos como o *Bidirectional Long Short-Term Memory (BiLSTM)*, melhorando a captura de contextos e dependências semânticas [Pimpalkar and R 2022, Kamyab et al. 2021].
- **Word2Vec:** Caracterizado por realizar a captura de características como associações semânticas e sintáticas entre palavras, permitindo identificar palavras semanticamente relacionadas mesmo que não apareçam explicitamente juntas no texto [Mikolov et al. 2013, Khan et al. 2023].
- **FastText:** Representa cada palavra como uma soma de suas subpalavras, onde uma subpalavra é representada por um *n-gram*, dotando-o da capacidade de gerar representações vetoriais mais robustas, especialmente útil ao lidar com palavras raras ou fora do vocabulário, as quais são comumente encontradas nos textos informais provenientes das redes sociais [Bojanowski et al. 2016, Ombabi et al. 2020].

Estudos mais recentes ainda destacam o uso de *embeddings* contextuais para a extração de características, isso porque eles são gerados por modelos pré-treinados, capazes de incorporar o contexto de cada palavra dentro da frase de forma dinâmica, representando um avanço significativo para a área [Abas et al. 2021]. Os principais casos encontrados sob este contexto são:

- **BERT:** O *Bidirectional Encoder Representations from Transformers* é um modelo capaz de aprender representações profundas de linguagem de forma bidirecional, considerando o contexto à esquerda e à direita de cada palavra em uma frase, permitindo capturar nuances e informações de maior complexidade [Devlin et al. 2019, Kokab et al. 2022, Talaat 2023]
- **RoBERTa:** O *Robustly Optimized BERT Pretraining Approach* é uma variação do *BERT*, removendo a tarefa de predição da próxima sentença, utilizando *batches* maiores e realizando o treinamento por mais tempo, o que o torna mais

robusto e capaz de capturar tanto informações sequenciais quanto contextuais [Liu et al. 2019, Tan et al. 2022].

- **DistilBERT**: O *Distilled BERT* também é uma variação do *BERT* original, mas utiliza menos parâmetros e por isso consegue atingir uma maior velocidade de inferência, podendo ainda ser empregado para tarefas complexas, como a classificação de múltiplos aspectos em um único texto [Sanh et al. 2020, Tao and Fang 2020].

Além das versões mais comuns do *BERT* mencionadas anteriormente, existem ainda vários outros modelos derivados, como o *Multilingual BERT (mBERT)*, que permite processar e analisar textos em diversos idiomas de maneira simultânea [Sunitha et al. 2022]. Esta grande diversidade de variantes reflete a ampla popularidade e aceitação do *BERT*, especialmente devido à sua capacidade de capturar profundamente as relações contextuais e semânticas, superando tanto as técnicas baseadas em frequência quanto as baseadas em *embeddings* distribuídos [Araujo et al. 2022, Tan et al. 2022, Kokab et al. 2022], ocupando lugar de destaque no estado da arte.

3.2.3. Modelos de treinamento

A escolha dos modelos também é amplamente debatida na literatura especializada. Modelos clássicos de *machine learning*, como *Support Vector Machine (SVM)*, *Random Forest (RF)* e regressão logística são utilizados frequentemente como *benchmark*, porém têm demonstrado limitações ao lidar com nuances linguísticas complexas e sequências contextuais extensas [Yousaf et al. 2021, Chiong et al. 2021]. Em contraste, modelos de *deep learning*, principalmente as *Recurrent Neural Networks (RNNs)* como *Long Short-Term Memory (LSTM)* e *Gated Recurrent Units (GRU)*, têm sido frequentemente empregados por conta da sua maior capacidade de capturar dependências temporais e contextuais [Pimpalkar and R 2022, Ombabi et al. 2020, Behera et al. 2021], gerando reflexo direto em sua popularidade na literatura. A figura 7 mostra que, desde 2023, os trabalhos fazem mais referência às técnicas de *deep learning* em detrimento do *machine learning* clássico. Além disso, se observarmos atentamente o crescimento de cada evolução isoladamente, percebemos que as menções a *machine learning* apresentam um caráter linear constante, enquanto o *deep learning* tem crescimento mais acentuado, indicando uma possível permanência em posição de destaque.

Outro destaque se dá para a utilização dos modelos híbridos, assim conhecidos por combinarem uma ou mais abordagens de treinamento, de forma a aproveitar as vantagens de cada método e buscar a mitigação de seus pontos fracos [Khan et al. 2022]. Podemos observar combinações de *CNNs* e *RNNs*, por exemplo, onde o modelo resultante obtém as vantagens das *CNNs* na extração de características locais importantes e das *RNNs* na captura de dependências temporais de longo alcance, demonstrando alto nível de performance [Abas et al. 2021, Ahmad et al. 2021, Ombabi et al. 2020]. Ainda é possível encontrar arquiteturas avançadas como *Capsule Networks* e mecanismos de atenção integrados a modelos *transformer*, oferecendo maior capacidade interpretativa e precisão em cenários complexos, além de demonstrar grande sucesso no tratamento de textos informais e demonstrar capacidade de lidar com dados ruidosos de maneira eficiente [Kokab et al. 2022, Sunitha et al. 2022].

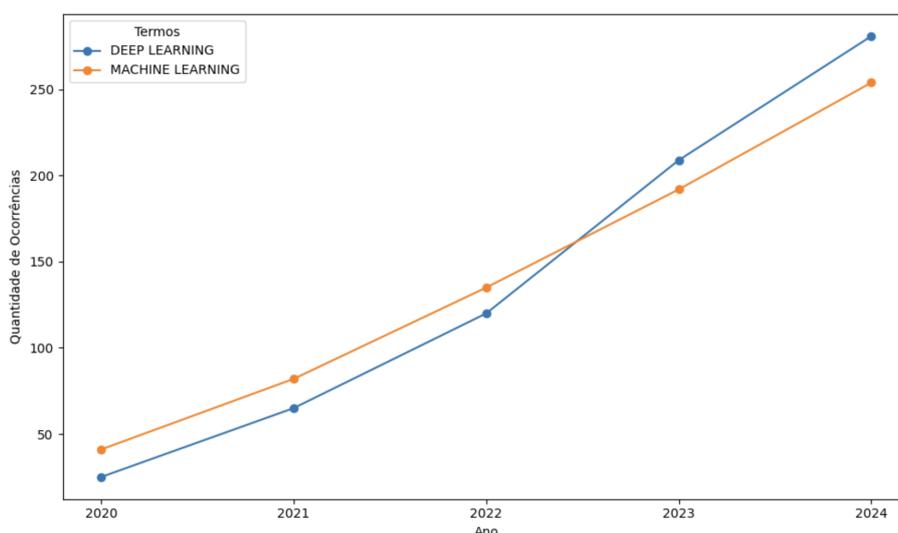


Figura 7. Evolução de referências a *Machine Learning* e *Deep Learning*

Em se tratando especificamente da análise de sentimentos baseada em aspectos, é possível perceber a existência de desafios particulares no que se refere à adoção de modelos com a capacidade de atribuir os sentimentos associados a cada um deles de forma independente. Um dos impactos negativos está relacionado aos próprios *datasets* utilizados para o treinamento, os quais, em sua maioria, são responsáveis por atribuir um único rótulo a cada instância de texto, reduzindo todo o conteúdo a uma única polaridade [Tao and Fang 2020]. Um outro problema reside na complexidade natural de desassociação entre sentimento geral do texto e o sentimento a respeito de um tópico específico [Consoli et al. 2022]. Neste sentido, a correta representação das características acaba por impactar o desempenho do modelo, demonstrando a importância da combinação entre modelos e técnicas de extração de características. Algumas das principais combinações analisadas podem ser conferidas através da tabela 5.

Artigo	Modelo	Técnica de representação
[Behera et al. 2021]	<i>CNN + LSTM</i>	<i>Word2Vec</i>
[Abas et al. 2021]	<i>CNN</i>	<i>BERT</i>
[Talaat 2023]	<i>BiLSTM</i>	<i>DistilBERT + RoBERTa</i>
[Pimpalkar and R 2022]	<i>CNN + BiLSTM</i>	<i>GloVe</i>
[Pathak et al. 2021]	<i>LSTM</i>	<i>TF-IDF + Word2Vec</i>

Tabela 5. Combinações entre modelos e técnicas de representação

3.2.4. Avaliação

A avaliação de desempenho para as abordagens realizadas também é amplamente explorada na literatura especializada. De modo geral, as métricas mais empregadas para a avaliação dos modelos não variam muito daquelas comumente utilizadas no contexto de aprendizagem de máquina. Podem ser vistos cenários muito positivos onde as métricas de acurácia, precisão e *F1-score* são utilizadas para comparar o desempenho dos diver-

sos classificadores [Yousaf et al. 2021], atingindo taxas de 94%, 96% e 95%, respectivamente. Há ainda a existência de aplicações que empregam as mesmas métricas, enfatizando o uso do *F1-score* como métrica principal [Tan et al. 2022], focando em aprimorar os valores da métrica, o que é alcançado pelo avanço de 88% para 93% ao migrar do uso de *LSTM* puro para um modelo híbrido. Além destas métricas, é possível encontrar materiais que utilizam o *recall* como métrica base [Talaat 2023], reportando valores superiores a 92% nos modelos desenvolvidos.

Além dos modos de avaliação acima citados, alguns estudos adotam indicadores baseados em curvas, como a *Receiver Operating Characteristic (ROC)* e a curva *Precision-Recall (PR)*, com os respectivos valores em torno de 0,98 e 0,95, demonstrando excelente distinção entre as classes [Behera et al. 2021, Tan et al. 2022]. Estas técnicas são especialmente relevantes para avaliar classificadores em diferentes limiares de decisão, principalmente em contextos onde o desequilíbrio entre classes se faz presente, uma vez que métricas como a acurácia podem mascarar o desempenho real do modelo ao favorecer a classe dominante, o que as torna bastante relevantes quando o intuito é observar o desempenho do modelo em cenários mais próximos da realidade [Chiong et al. 2021, Singh et al. 2022].

Indo mais adiante, também podemos observar a presença de trabalhos que recorrem ao uso de técnicas estatísticas formais para comparação rigorosa entre os modelos, como a aplicação de testes *t* pareados para verificar a significância estatística das diferenças observadas entre modelos [Behera et al. 2021]. A aplicação desta estratégia chega a proporcionar aumentos nos valores do *F1-score*, de 91% para 95%, com os testes *t* sendo fundamentais para garantir que os ganhos não sejam atribuídos por acaso, reforçando a robustez dos resultados e a validade das conclusões experimentais.

Vale ainda destacar que a avaliação de resultados não se restringe aos modelos mais complexos baseados em *machine learning* e *deep learning*. A partir do enfoque neste aspecto, é possível constatar que os métodos baseados em algoritmos léxicos acabam sendo inferiores não apenas em termos de escalabilidade, mas também em termos de resultados obtidos, uma vez que suas métricas atingem tetos menores quando comparados com os modelos mais sofisticados, a exemplo da acurácia que atinge o limite de 85%, enquanto os métodos de *machine learning* e *deep learning* apresentam resultados entre 90% e 95%, de maneira respectiva [Al-Qablan et al. 2023].

4. Análise crítica

Ao analisar as publicações, talvez a primeira coisa a ser observada seja o vasto contexto de utilização da análise de sentimentos em várias aplicações especializadas desde o setor público até o mercado financeiro, o que mostra a sua multidisciplinaridade e flexibilidade [Sufi and Khalil 2024, Parekh et al. 2022]. Outro ponto que inicialmente também chama a atenção está relacionado à grande quantidade de estudos com temáticas relacionadas à pandemia de COVID-19. Esse fenômeno é compreensível dada a importância sanitária, social e econômica do tema, que dominou discussões públicas globais durante o período analisado no presente trabalho. É interessante notar que, mesmo dentro de um tema central como a pandemia, ainda é possível observar a flexibilidade das análises, uma vez que são utilizadas para elucidar diferentes óticas como a disseminação de notícias falsas, a percepção pública a respeito da vacinação,

além do impacto psicológico coletivo, demonstrando grande relevância social e prática [Iwendi et al. 2022, Sunitha et al. 2022, Aygun et al. 2022].

Neste contexto, naturalmente desenvolveu-se um maior interesse pela área por parte de diversos setores, em particular o empresarial. Este maior interesse, por sua vez, acaba por impulsionar o número de pesquisas e trabalhos relacionados ao tema. No entanto, o crescimento no número de trabalhos não está necessariamente atrelado a um crescimento proporcional da qualidade dos mesmos. A figura 8, por exemplo, evidencia que a média de citações aos trabalhos relacionados apresentou uma queda bastante acentuada nos últimos dois anos, o que pode indicar uma queda na qualidade dos novos artigos ou a ocorrência de poucas novidades. Vale ainda analisar mais a fundo esta última possibilidade, uma vez que, durante a análise dos artigos, verificou-se uma similaridade grande entre alguns temas abordados. Enquanto uns estudos abordam a detecção de notícias falsas de forma geral [Balshetwar et al. 2023], outros abordam com foco em contextos específicos, como a pandemia [Iwendi et al. 2022]. Ou seja, a alta gama de aplicações já desenvolvidas pode estar reduzindo a janela de inovação das aplicações, o que, somado à primeira queda no número de trabalhos ocorrida entre os anos de 2023 e 2024, fato exibido na figura 3, pode estar indicando que a área caminha para uma estabilização.

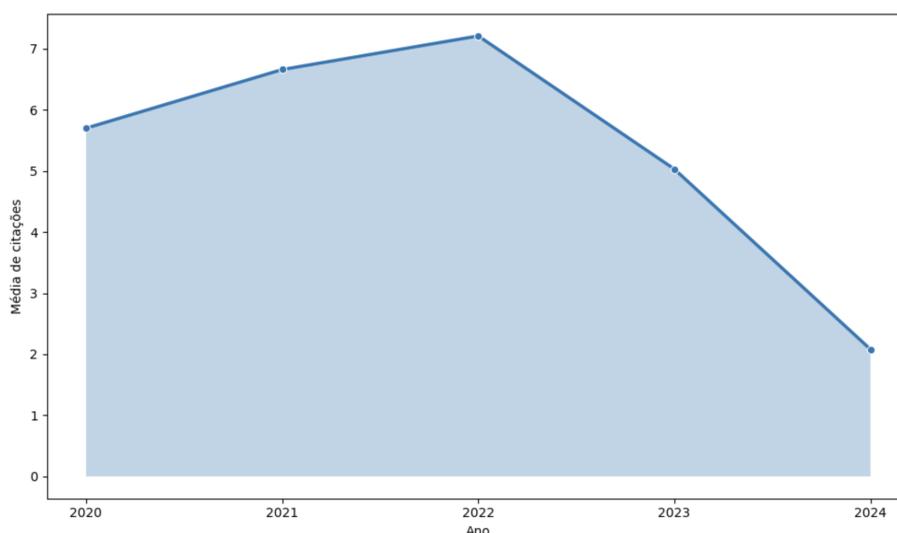


Figura 8. Média de citações por ano

Outro aspecto de muita similaridade entre os trabalhos se dá pelo uso excessivo do *X* como fonte de dados, fato observado na grande maioria das análises, sendo rara a ocorrência de estudos que, por exemplo, utilizam dados provenientes do *Facebook* ou *Reddit* como base [Haque et al. 2023, Oryngozha et al. 2024]. A escolha pelo *X* se deve, sobretudo, à facilidade de acesso às publicações por meio de sua *API* e ao grande volume de postagens disponíveis a todo momento sobre tópicos emergentes, o que contribui para torná-la uma das principais redes sociais alvo da análise de sentimentos [Aslan 2023]. Contudo, essa concentração gera limitações relevantes, principalmente com relação à generalização dos resultados obtidos. O comportamento dos usuários no *X* pode não representar adequadamente todas as redes sociais, especialmente aquelas com características estruturais e demográficas distintas. Ou seja, a literatura atual pode apresentar um viés metodológico que restringe a aplicabilidade dos resultados em contextos

sociais distintos, ou enviesar os resultados com base em usuários com um determinado perfil.

Além disso, também é possível observar uma forte barreira linguística presente na grande maioria dos estudos, isso porque os mesmos priorizam o inglês como idioma central para a confecção de suas aplicações e, conseqüentemente, como alvo de seus casos de uso. Tomemos como exemplo o idioma árabe, o qual figura entre os cinco idiomas mais falados no mundo, mas que não é abordado em grande escala por parte dos estudos especializados e, os que o fazem, não apresentam resultados tão satisfatórios quando comparados com aqueles voltados para o inglês [Ombabi et al. 2020, Rahma et al. 2023]. Países como a Turquia também enfrentam o mesmo problema pois, assim como a Arábia Saudita, está presente entre os países que mais contribuem com o desenvolvimento da área em termos de quantidade de publicações e relevância, mas possui poucas aplicações voltadas ao seu idioma.

A disparidade encontrada a respeito da quantidade e relevância dos trabalhos focados no inglês quando comparados com os idiomas asiáticos se torna intrigante ao observarmos que a esmagadora maioria das publicações especializadas é desenvolvida nos próprios países asiáticos, fato já abordado anteriormente. No entanto, a situação é agravada quando percebemos a disparidade não apenas com relação à quantidade de artigos, mas também a tendência de desenvolvimento destes, onde a Índia encontra-se em um patamar bastante elevado quando comparada aos demais países e com tendência de se destacar ainda mais, o que pode ser visto na figura 9. Tal falta de diversidade linguística pode culminar com a dificuldade de compreensão plena a respeito das nuances culturais e linguísticas relacionadas à análise de sentimentos. Idiomas com estruturas linguísticas e culturais radicalmente distintas possuem desafios únicos, incluindo complexidades morfológicas, ambigüidade linguística, além de necessitarem de novas abordagens de pré-processamento.

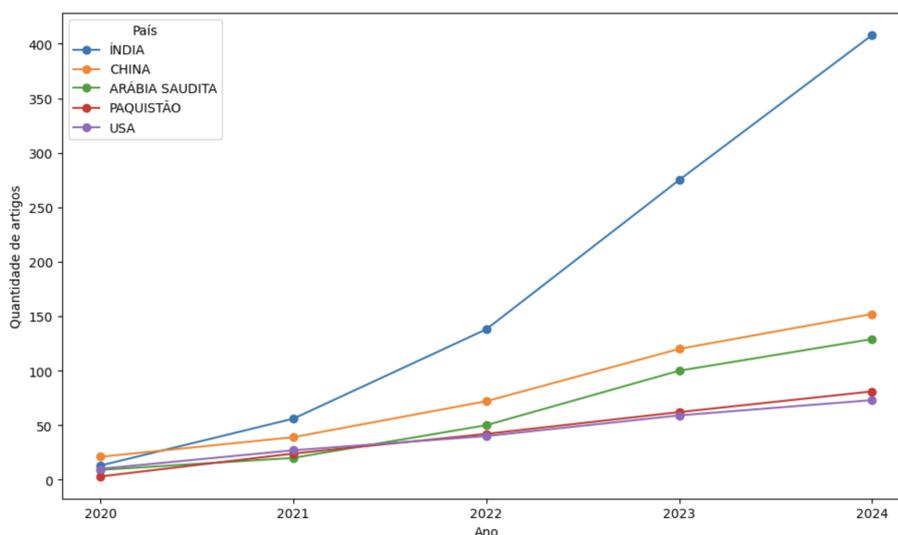


Figura 9. Quantidade de publicações por país

Como visto anteriormente, os modelos de *deep learning* vêm ganhando destaque quando o assunto são os aspectos técnicos utilizados na análise de sentimentos, uma vez

que estes modelos têm proporcionado excelentes resultados em suas métricas avaliadas, geralmente com valores superiores a 90%, refletindo o sucesso na captura de contextos semânticos e sintáticos complexos, mesmo que algumas melhorias ainda sejam necessárias em métricas como a acurácia [Ombabi et al. 2020, Tan et al. 2022, Talaat 2023]. Entretanto, observa-se que esses altos valores métricos podem acabar mascarando certos problemas, isso porque muitas das bases de dados utilizadas no processo de treinamento possuem dados mal rotulados, ruidosos ou fora do vocabulário base, o que pode fazer com que os modelos não tenham bom desempenho quando submetidos a casos de uso reais [Kokab et al. 2022]. Adicionalmente, os estudos não abordam técnicas voltadas ao aprendizado dinâmico dos modelos, o que pode vir a ser fundamental em um cenário como o atual, onde o volume de interações cresce tão rápido que chega a atingir a escala do *Big Data* [Behera et al. 2021], constantemente evidenciando o surgimento de novos termos, tendências e mudanças de hábitos, fazendo com que o modelo possa ficar depreciado rapidamente. Além disso, os métodos de *deep learning* apresentam escassez relacionada a questões de interpretabilidade e explicabilidade dos resultados obtidos [Akula and Garibay 2021], o que tem sido cada vez mais exigido, sobretudo em aplicações com foco em tópicos sensíveis como a detecção de depressão ou a análise de finanças, onde a compreensão do porquê torna-se mais importante do que o resultado em si por conta dos possíveis impactos negativos sobre a vida financeira ou até mesmo a saúde dos indivíduos.

De maneira geral, as publicações possuem alta qualidade em termos técnicos e metodológicos, mas muitas vezes são superficiais no que se refere à discussão sobre limitações metodológicas, viés de seleção de dados e questões éticas associadas ao uso dos dados de cunho social. Apesar de muitos trabalhos fornecerem análises robustas de desempenho e comparações entre modelos [Yousaf et al. 2021, Iwendi et al. 2022], trazem discussões amplas a respeito dos potenciais vieses ou implicações éticas do uso dos dados analisados, a exemplo da análise da personalidade de um usuário sem consentimento prévio e para quais finalidades esta informação será utilizada.

5. Conclusão

O presente trabalho apresentou uma revisão sistemática a respeito dos métodos computacionais empregados para automatizar a análise de sentimentos em textos de redes sociais através de um protocolo de busca transparente, a inclusão de artigos de diferentes bases científicas e a análise crítica comparativa que permitiu sintetizar tendências técnicas e lacunas temáticas. O levantamento realizado mostrou que a literatura se encontra em um estágio avançado de maturidade, destacando-se especialmente pela utilização de técnicas modernas de aprendizado de máquina em conjunto com métodos de pré-processamento de dados que, pelo alto grau de detalhamento, evidenciam a preocupação com a robustez metodológica. Além disso, também foram apresentados os possíveis níveis de classificação e os vastos contextos de uso da área, que proporcionam a ela uma alta versatilidade e adaptabilidade, figurando entre os principais pontos fortes identificados.

No entanto, é importante destacar alguns pontos analisados e que merecem atenção, iniciando pela forte concentração em dados provenientes do *Twitter* na realização dos estudos, o que pode restringir a generalização dos resultados obtidos para outras plataformas sociais com diferentes formatos de conteúdo e perfis de utilização. Vale pontuar que o recorte temporal adotado para a condução deste estudo pode ter contribuído

para este ponto, uma vez que, nesse intervalo, o *Twitter* manteve a *API* pública mais acessível entre as grandes redes sociais, sendo amplamente utilizada como fonte primária de informação e pesquisas, sobretudo durante a pandemia de COVID-19. Outro aspecto negativo se dá pela limitada diversidade linguística abordada pela maioria dos estudos, com predominância de análises focadas em textos em inglês, deixando lacunas significativas em relação a idiomas complexos, como árabe, turco e outros idiomas presentes entre os mais falados globalmente. Ademais, percebe-se uma carência importante de investigações aprofundadas sobre interpretabilidade e explicabilidade dos modelos, questões essenciais para aplicações sensíveis como saúde mental, segurança pública e decisões financeiras, todos estes temas presentes nas aplicações existentes na literatura sem o devido detalhamento a respeito da capacidade de explicação dos resultados.

Neste cenário, trabalhos futuros podem valer-se de abordagens com foco em outras redes sociais, como *Reddit*, *Instagram* ou *TikTok*, além de realizar comparações destes novos modelos com aqueles restritos baseados apenas nos dados do *Twitter*. Outro fator que pode ser abordado está relacionado à restrição da grande maioria dos modelos desenvolvidos a contextos específicos, sendo necessário um maior volume de aplicações de uso geral. É bem sabido que existem dificuldades referentes à qualidade e volume dos dados utilizados para o treinamento, mas, neste contexto, aplicações baseadas em aprendizagem dinâmica podem levar à obtenção de bons resultados, o que poderia vir a proporcionar aplicações de análise de sentimentos em conjunto com técnicas de aprendizagem por reforço, por exemplo. Tais abordagens podem proporcionar uma redução no volume de dados necessários para o treinamento, além de terem condições de ser escaláveis para aplicações satisfatórias em outros idiomas.

Por fim, este trabalho reconhece que os recortes realizados, seja a nível temporal ou a nível qualitativo, podem representar limitações para as análises aqui realizadas. A nível temporal, publicações recentes e com boa contribuição científica podem ter ficado de fora da análise. De modo semelhante, pode haver publicações fora do limiar de qualidade adotado que agregariam para uma análise mais rica e detalhada, proporcionando um maior valor científico.

Referências

- Abas, A. R., Elhenawy, I., Zidan, M., and Othman, M. (2021). BERT-CNN: A deep learning model for detecting emotions from text. *Computers, Materials and Continua*, 71(2):2943–2961.
- Ahmad, H., Asghar, M. U., Asghar, M. Z., Khan, A., and Mosavi, A. H. (2021). A hybrid deep learning technique for personality trait classification from text. *IEEE Access*, 9:146214–146232.
- Akula, R. and Garibay, I. (2021). Interpretable multi-head self-attention architecture for sarcasm detection in social media. *Entropy*, 23(4):394.
- Al-Qablan, T. A., Noor, M. M., Al-Betar, M. A., et al. (2023). A survey on sentiment analysis and its applications. *Neural Computing and Applications*, 35:21567–21601.
- Alattar, F. and Shaalan, K. (2021). Using artificial intelligence to understand what causes sentiment changes on social media. *IEEE Access*, 9:61756–61767.

- Aljedaani, W., Rustam, F., Mkaouer, M. W., Ghallab, A., Rupapara, V., Washington, P. B., Lee, E., and Ashraf, I. (2022). Sentiment analysis on twitter data integrating textblob and deep learning models: The case of us airline industry. *Knowledge-Based Systems*, 255:109780.
- Alzamzami, F., Hoda, M., and Saddik, A. E. (2020). Light gradient boosting machine for general sentiment classification on short texts: A comparative evaluation. *IEEE Access*, 8:101840–101858.
- Araujo, A. F., Gôlo, M. P. S., and Marcacini, R. M. (2022). Opinion mining for app reviews: an analysis of textual representation and predictive models. *Automated Software Engineering*, 29(5).
- Aria, M. and Cuccurullo, C. (2017). bibliometrix: An r-tool for comprehensive science mapping analysis. *Journal of Informetrics*, 11(4):959–975.
- Aslan, S. (2023). A deep learning-based sentiment analysis approach (mf-cnn-bilstm) and topic modeling of tweets related to the ukraine–russia conflict. *Applied Soft Computing*, 143:110404.
- Aygun, I., Kaya, B., and Kaya, M. (2022). Aspect based twitter sentiment analysis on vaccination and vaccine types in covid-19 pandemic with deep learning. *IEEE Journal of Biomedical and Health Informatics*, 26(5):2360–2369.
- Bagherzadeh, S., Shokouhyar, S., Jahani, H., and Sigala, M. (2021). A generalizable sentiment analysis method for creating a hotel dictionary: using big data on tripadvisor hotel reviews. *Journal of Hospitality and Tourism Technology*, 12(2):210–238.
- Balshetwar, S. V., RS, A., and R, D. J. (2023). Fake news detection in social media based on sentiment analysis using classifier techniques. *Multimedia Tools and Applications*, 82:35781–35811.
- Behera, R. K., Jena, M., Rath, S. K., and Misra, S. (2021). Co-lstm: Convolutional lstm model for sentiment analysis in social big data. *Information Processing & Management*, 58(1):102435.
- Berka, P. (2020). Sentiment analysis using rule-based and case-based reasoning. *Journal of Intelligent Information Systems*, 55:51–66.
- Bojanowski, P., Grave, E., Joulin, A., and Mikolov, T. (2016). Enriching word vectors with subword information. *Transactions of the Association for Computational Linguistics*, 5.
- Chiong, R., Budhi, G. S., and Dhakal, S. (2021). Combining sentiment lexicons and content-based features for depression detection. *IEEE Intelligent Systems*, 36(6):99–105.
- Consoli, S., Barbaglia, L., and Manzan, S. (2022). Fine-grained, aspect-based sentiment analysis on economic and financial lexicon. *Knowledge-Based Systems*, 247:108781.
- Devlin, J., Chang, M.-W., Lee, K., and Toutanova, K. (2019). Bert: Pre-training of deep bidirectional transformers for language understanding.
- Gupta, P., Kumar, S., Suman, R. R., and Kumar, V. (2021). Sentiment analysis of lock-down in india during covid-19: A case study on twitter. *IEEE Transactions on Computational Social Systems*, 8(4):992–1002.

- Hamza, M. A., Hashim, A. H. A., Motwakel, A., et al. (2024). Robust tweets classification using arithmetic optimization with deep learning for sustainable urban living. *SN Computer Science*, 5:549.
- Haque, R., Islam, N., Tasneem, M., and Das, A. K. (2023). Multi-class sentiment classification on bengali social media comments using machine learning. *International Journal of Cognitive Computing in Engineering*, 4:21–35.
- Hasib, K. M., Islam, M. R., Sakib, S., Akbar, M. A., Razzak, I., and Alam, M. S. (2023). Depression detection from social networks data based on machine learning and deep learning techniques: An interrogative survey. *IEEE Transactions on Computational Social Systems*, 10(4):1568–1586.
- Iwendi, C., Mohan, S., Khan, S., Ibeke, E., Ahmadian, A., and Ciano, T. (2022). Covid-19 fake news sentiment analysis. *Computers and Electrical Engineering*, 101:107967.
- Kamyab, M., Liu, G., and Adjeisah, M. (2021). Attention-based cnn and bi-lstm model based on tf-idf and glove word embedding for sentiment analysis. *Applied Sciences*, 11(23):11255.
- Kaur, G. and Sharma, A. (2023). A deep learning-based model using hybrid feature extraction approach for consumer sentiment analysis. *Journal of Big Data*, 10(1):5.
- Khan, L., Amjad, A., Afaq, K. M., and Chang, H.-T. (2022). Deep sentiment analysis using cnn-lstm architecture of english and roman urdu text shared in social media. *Applied Sciences*, 12(5):2694.
- Khan, Z. A., Xia, Y., Ali, S., Khan, J. A., Askar, S. S., Abouhawwash, M., and El-Rashidy, N. (2023). Identifying hot topic trends in streaming text data using news sequential evolution model based on distributed representations. *IEEE Access*, 11:98787–98804.
- Kokab, S. T., Asghar, S., and Naz, S. (2022). Transformer-based deep learning models for the sentiment analysis of social media data. *Array*, 14:100157.
- Kumar, L. K., Thatha, V. N., Udayaraju, P., Siri, D., Kiran, G. U., Jagadesh, B. N., and Vatambeti, R. (2024). Analyzing public sentiment on the amazon website: A gsk-based double path transformer network approach for sentiment analysis. *IEEE Access*, 12:28972–28987.
- Lee, E., Rustam, F., Ashraf, I., Washington, P. B., Narra, M., and Shafique, R. (2022a). Inquest of current situation in afghanistan under taliban rule using sentiment analysis and volume analysis. *IEEE Access*, 10:10333–10348.
- Lee, E., Rustam, F., Washington, P. B., Barakaz, F. E., Aljedaani, W., and Ashraf, I. (2022b). Racism detection by analyzing differential opinions through sentiment analysis of tweets using stacked ensemble gcr-nn model. *IEEE Access*, 10:9717–9728.
- Liu, H., Chatterjee, I., Zhou, M., Lu, X. S., and Abusorrah, A. (2020). Aspect-based sentiment analysis: A survey of deep learning methods. *IEEE Transactions on Computational Social Systems*, 7(6):1358–1375.
- Liu, Y., Ott, M., Goyal, N., Du, J., Joshi, M., Chen, D., Levy, O., Lewis, M., Zettlemoyer, L., and Stoyanov, V. (2019). Roberta: A robustly optimized bert pretraining approach.
- Mikolov, T., Chen, K., Corrado, G., and Dean, J. (2013). Efficient estimation of word representations in vector space.

- Mishra, S., Shukla, P., and Agarwal, R. (2022). Analyzing machine learning enabled fake news detection techniques for diversified datasets. *Wireless Communications and Mobile Computing*, 2022(Article ID 1575365):1–18.
- Moher, D., Liberati, A., Tetzlaff, J., and Altman, D. G. (2010). Preferred reporting items for systematic reviews and meta-analyses: The prisma statement. *International Journal of Surgery*, 8(5):336–341.
- Molero, J. M., Pérez-Martín, J., Rodrigo, A., and Peñas, A. (2023). Offensive language detection in spanish social media: Testing from bag-of-words to transformers models. *IEEE Access*, 11:95639–95652.
- Nguyen, A., Longa, A., Luca, M., Kaul, J., and Lopez, G. (2022). Emotion analysis using multilayered networks for graphical representation of tweets. *IEEE Access*, 10:99467–99478.
- Ombabi, A. H., Ouarda, W., and Alimi, A. M. (2020). Deep learning cnn-lstm framework for arabic sentiment analysis using textual information shared in social networks. *Social Network Analysis and Mining*, 10(1):53.
- Omuya, E. O., Okeyo, G., and Kimwele, M. (2023). Sentiment analysis on social media tweets using dimensionality reduction and natural language processing. *Engineering Reports*, 5(3):e12579.
- Oryngoza, N., Shamo, P., and Igali, A. (2024). Detection and analysis of stress-related posts in reddit’s academic communities. *IEEE Access*, 12:14932–14948.
- Pagani, R. N., Kovaleski, J. L., and Resende, L. M. (2015). Methodi ordinatio: a proposed methodology to select and rank relevant scientific papers encompassing the impact factor, number of citation, and year of publication. *Scientometrics*, 105:2109–2135.
- Parekh, R., Patel, N. P., Thakkar, N., Gupta, R., Tanwar, S., Sharma, G., Davidson, I. E., and Sharma, R. (2022). DL-guess: Deep learning and sentiment analysis-based cryptocurrency price prediction. *IEEE Access*, 10:35398–35409.
- Pathak, A. R., Pandey, M., and Rautaray, S. (2021). Topic-level sentiment analysis of social media data using deep learning. *Applied Soft Computing*, 108:107440.
- Peng, S., Cao, L., Zhou, Y., Ouyang, Z., Yang, A., Li, X., Jia, W., and Yu, S. (2022). A survey on deep learning for textual emotion analysis in social networks. *Digital Communications and Networks*, 8(5):745–762.
- Pennington, J., Socher, R., and Manning, C. (2014). Glove: Global vectors for word representation. *Empirical Methods in Natural Language Processing (EMNLP)*, 14:1532–1543.
- Pimpalkar, A. and R, J. R. R. (2022). MBiLSTM GloVe: Embedding glove knowledge into the corpus using multi-layer bilstm deep learning model for social media sentiment analysis. *Expert Systems with Applications*, 203:117581.
- Potamias, R. A., Siolas, G., and Stafylopatis, A. G. (2020). A transformer-based approach to irony and sarcasm detection. *Neural Computing and Applications*. arXiv:1911.10401 [cs.CL].

- Qorib, M., Oladunni, T., Denis, M., Ososanya, E., and Cotae, P. (2023). Covid-19 vaccine hesitancy: Text mining, sentiment analysis and machine learning on covid-19 vaccination twitter dataset. *Expert Systems with Applications*, 212:118715.
- Rahma, A., Azab, S. S., and Mohammed, A. (2023). A comprehensive survey on arabic sarcasm detection: Approaches, challenges and future trends. *IEEE Access*, 11:18261–18280.
- Salton, G. and Buckley, C. (1988). Term-weighting approaches in automatic text retrieval. *Information Processing & Management*, 24(5):513–523.
- Sanh, V., Debut, L., Chaumond, J., and Wolf, T. (2020). Distilbert, a distilled version of bert: smaller, faster, cheaper and lighter.
- Shannon, C. E. (1948). A mathematical theory of communication. *The Bell System Technical Journal*, 27(3):379–423.
- Singh, C., Imam, T., Wibowo, S., and Grandhi, S. (2022). A deep learning approach for sentiment analysis of covid-19 reviews. *Applied Sciences*, 12(8):3709.
- Singh, N. K., Tomar, D. S., and Sangaiah, A. K. (2020). Sentiment analysis: a review and comparative analysis over social media. *Journal of Ambient Intelligence and Humanized Computing*, 11:97–117.
- Sufi, F. K. and Khalil, I. (2024). Automated disaster monitoring from social media posts using ai-based location intelligence and sentiment analysis. *IEEE Transactions on Computational Social Systems*, 11(4):4614–4624.
- Sunitha, D., Patra, R. K., Babu, N. V., Suresh, A., and Gupta, S. C. (2022). Twitter sentiment analysis using ensemble based deep learning model towards covid-19 in india and european countries. *Pattern Recognition Letters*, 158:164–170.
- Talaat, A. S. (2023). Sentiment analysis classification system using hybrid bert models. *Journal of Big Data*, 10:110.
- Tan, K. L., Lee, C. P., Anbananthen, K. S. M., and Lim, K. M. (2022). Roberta-lstm: A hybrid model for sentiment analysis with transformer and recurrent neural network. *IEEE Access*, 10:21517–21525.
- Tao, J. and Fang, X. (2020). Toward multi-label sentiment analysis: a transfer learning based approach. *Journal of Big Data*, 7(1):1.
- Tiwari, D., Nagpal, B., Bhati, B. S., et al. (2023). A systematic review of social network sentiment analysis with comparative study of ensemble-based techniques. *Artificial Intelligence Review*, 56:13407–13461.
- Usman, M., Mujahid, M., Rustam, F., Flores, E., Vidal Mazón, J. L., Díez, I. T., and Ashraf, I. (2024). Analyzing patients satisfaction level for medical services using twitter data. *PeerJ Computer Science*, 10:e1697.
- Wankhade, M., Rao, A., and Kulkarni, C. (2022). A survey on sentiment analysis methods, applications, and challenges. *Artificial Intelligence Review*, 55:5731–5780.
- Westermann, A. and Forthmann, J. (2021). Social listening: a potential game changer in reputation management. how big data analysis can contribute to understanding

stakeholders' views on organisations. *Corporate Communications: An International Journal*, 26(1):2–22.

Xu, L., Li, L., Jiang, Z., Sun, Z., Wen, X., Shi, J., Sun, R., and Qian, X. (2021). A novel emotion lexicon for chinese emotional expression analysis on weibo: Using grounded theory and semi-automatic methods. *IEEE Access*, 9:92757–92768.

Yousaf, A., Umer, M., Sadiq, S., Ullah, S., Mirjalili, S., Rupapara, V., and Nappi, M. (2021). Emotion recognition by textual tweets classification using voting classifier (lr-sgd). *IEEE Access*, 9:6286–6295.

Ficha de identificação da obra elaborada pelo autor,
através do programa de geração automática do SIB/UFPE

Santos, Daniel Nascimento dos.

Automação da análise de sentimentos em textos de redes sociais - uma
revisão qualitativa da literatura / Daniel Nascimento dos Santos. - Recife, 2025.
24p : il., tab.

Orientador(a): Adiel Teixeira de Almeida Filho

Trabalho de Conclusão de Curso (Graduação) - Universidade Federal de
Pernambuco, Centro de Informática, Sistemas de Informação - Bacharelado,
2025.

Inclui referências, apêndices.

1. Automação. 2. Aprendizagem de máquina. 3. Análise de sentimentos. 4.
Redes sociais. 5. Análise textual. I. Almeida Filho, Adiel Teixeira de.
(Orientação). II. Título.

000 CDD (22.ed.)

Daniel Nascimento dos Santos

**Automação da análise de sentimentos em textos de redes sociais - uma
revisão qualitativa da literatura**

Trabalho de graduação apresentado ao curso de Sistemas de Informação do Centro de Informática da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do grau de Bacharel em Sistemas de Informação.

Aprovado em: 05/08/2025.

BANCA EXAMINADORA

Prof. Dr. Adiel Teixeira de Almeida Filho (Orientador)
Universidade Federal de Pernambuco - UFPE

Prof. Dr. George Darmiton da Cunha Cavalcanti (Examinador interno)
Universidade Federal de Pernambuco - UFPE