

Capítulo

1

Identificação de Câmaras de Eco em Redes Sociais Através de Detecção de Comunidade em Redes Complexas: Ferramentas, Tendências e Desafios

Nicollas Rodrigues de Oliveira, Dianne Scherly Varela de Medeiros,
Diogo Menezes Ferrazani Mattos

¹LabGen/MídiaCom - PPGEET/TET/TCE/UFF
Universidade Federal Fluminense (UFF)
Niterói, Brasil

{nicollas_rodrigues, diannescherly, diogo_mattos}@id.uff.br

Resumo

A câmara de eco é um fenômeno relacionado à tendência de usuários de redes sociais interagirem com outros usuários em grupos homogêneos e com ideias e opiniões semelhantes. Como resultado, a câmara de eco prejudica o contraditório e incentiva o fenômeno do viés de confirmação, fomentando ambientes propícios ao discurso de ódio e à propagação de notícias falsas (fake news). Este minicurso apresenta os principais algoritmos para a caracterização estrutural e técnicas que auxiliam na detecção de câmaras de eco. O minicurso se concentra em abordagens de descoberta de comunidades sobre um grafo de topologia criado de acordo com a difusão de informações em redes sociais. Detalham-se também algoritmos de caracterização de redes complexas e os índices de desempenho dessas abordagens. Além disso, o minicurso desenvolve uma atividade prática de captura de dados em redes sociais e análise para identificação de câmaras de eco. Por fim, são discutidos os desafios e ferramentas que focam no estudo de câmaras de eco em redes sociais online.

1.1. Introdução

A facilidade de acesso pervasivo e ubíquo para a publicação e consumo de informações torna as plataformas de redes sociais um importante meio de interação pública.

Este capítulo foi realizado com recursos do CNPq, CAPES, RNP, FAPERJ, FAPESP (2018/23062-5) e Prefeitura de Niterói/FEC/UFF (Edital PDPA 2020).

Estudos recentes revelam que 71% dos brasileiros recorreram a plataformas como o *Facebook* e o *Twitter* para se informarem¹. Apesar de hospedarem tanto conteúdos úteis para geração de conhecimento, quanto para o entretenimento, é latente a vocação das redes sociais em fomentar e repercutir conteúdos focado no discurso de ódio e em notícias falsas (*fake news*) [de Oliveira et al., 2020a]. Essa tendência de amplificar fenômenos indesejáveis é consequência direta da alteração do modelo de produção e consumo de informação. Tradicionalmente o processo de seleção de informação era mediado por jornalistas ou editores. Contudo, atualmente passou a ser exercido em redes sociais por todos e quaisquer usuários, com ou sem formação adequada para divulgação de notícias. Essa supressão ou ausência da mediação profissional especializada, contribui para degradação dos princípios de imparcialidade e legitimidade da informação, uma vez que usuários não treinados são mais suscetíveis ao fenômeno conhecido como “viés de confirmação”. Tal fenômeno expressa a tendência dos usuários absorverem e compartilharem informações que se aderem ao seu sistema de crenças, mesmo que essas informações sejam inverídicas. Igualmente recorrente nas redes sociais, o efeito da “câmara de eco” é um fenômeno social relacionado à tendência dos usuários em interagirem e ingressarem em grupos homogêneos com ideias semelhantes às suas. Embutido no cerne desse fenômeno está o conceito de *unfriending* que consiste na exclusão intencional de usuários com opiniões contrárias às adotadas na câmara de eco [Cota et al., 2019, de Oliveira et al., 2021a, Zollo et al., 2017].

Implicitamente o fenômeno da câmara de eco engloba mecanismos que alienam os membros da comunidade formada, impedindo o acesso a fontes de informação epistêmicas externas. Assim, as câmaras de eco funcionam sistematicamente para formar padrões ideológicos disfuncionais que impedem os integrantes da câmara de eco de se envolverem em buscas informativas além da sua comunidade intelectual. Além de impedir o acesso à informação, os mecanismos envolvidos na formação das câmaras de eco desacreditam ativamente informações externas à câmara. Como consequência, há um desequilíbrio epistêmico que poderia implicar apenas em omissão de pontos de vista contrários, mas que, devido à formação da câmara de eco, implica em uma desconfiança preventiva ideológica dando origem ao aprisionamento dos indivíduos em câmaras de eco [Donkers e Ziegler, 2021].

Algumas redes sociais, como *Reddit*² e *Gab*³, facilitam o processo de formação de câmaras de eco, uma vez que são naturalmente organizadas em comunidades relacionadas a um determinado tema. Recentemente, o *Whatsapp* divulgou o desenvolvimento da funcionalidade *Whatsapp Comunidades* capaz de agregar vários grupos em um mesmo espaço compartilhado⁴. Paralelamente, o *Twitter* lançou a *Roda do Twitter*⁵, um recurso que permite que o usuário selecione a audiência do conteúdo a ser publicado, podendo encaminhá-lo somente a um grupo limitado e editável de amigos. Embora almejem facilitar a comunicação, tais recursos reacendem preocupações sobre os potenciais impactos nocivos da divulgação de conteúdos em ambientes virtuais segregados, ajudando a inten-

¹Disponível em <https://www.kaspersky.com.br/blog/pesquisa-infodemia-impactos-vida-digital/17467/>.

²Disponível em <https://www.reddit.com/>.

³Disponível em <https://gab.com/>.

⁴Disponível em <https://blog.whatsapp.com/sharing-our-vision-for-communities-on-whatsapp>.

⁵Disponível em <https://help.twitter.com/pt/using-twitter/twitter-circle>.

sificar o viés de confirmação. Outro facilitador normalmente utilizado pelas plataformas de redes sociais é o algoritmo de recomendação, que fornece aos usuários mais do mesmo conteúdo consumido com base em seus comportamentos passados para moldar a preferência futura. Os usuários tendem a aceitar as recomendações e, adicionalmente, buscam ativamente mais informações sobre o conteúdo de interesse, devido ao viés de confirmação. Os algoritmos de recomendação também podem usar a popularidade de um conteúdo como indicativo de qualidade ou de preferência pessoal por um determinado conteúdo. No entanto, essa métrica de engajamento pode vir às custas da diversidade de opiniões [Sasahara et al., 2021]. Assim, o viés de confirmação e os algoritmos de recomendação criam uma espiral de auto-reforço. Como consequência, o ciclo de *feedback* entre algoritmos de recomendação e a psicologia humana eventualmente leva a uma câmara de eco que muda a visão de mundo dos usuários [Alatawi et al., 2021].

Um exemplo prático e preocupante das consequências da formação de câmaras de eco é o agravamento da polarização política nos últimos anos no mundo. Devido ao mecanismo de auto-reforço, as câmaras de eco ideológicas formadas alimentam ainda mais a polarização ao ampliar as lacunas de conhecimento entre grupos díspares. Recentemente, Fletcher *et al.* avaliaram o número de pessoas em câmaras de eco de notícias politicamente partidárias, abrangendo diferentes países europeus e os Estados Unidos. O estudo focou na contabilização de pessoas que usam apenas fontes de notícias *online* tendenciosas, sejam de esquerda ou de direita. Os resultados obtidos mostraram que no Reino Unido, cerca de 2% do público pesquisado integra uma câmara de eco inclinada para a esquerda, enquanto que cerca de 5% participam de uma câmara de eco inclinada para a direita. Tais proporções são semelhantes aos demais países analisados, com exceção dos EUA, onde estima-se que mais de 10% dos entrevistados confiam apenas em fontes de notícias partidárias [Fletcher et al., 2021].

O objetivo deste minicurso é apresentar os principais algoritmos, técnicas e métricas que auxiliam na caracterização estrutural e detecção de câmaras de eco (*echo chambers*) em redes sociais *online*. Diante das abordagens existentes de detecção de câmaras de eco, este minicurso foca na abordagem topológica. Essa abordagem explora a propagação do conteúdo entre os usuários e o padrão topológico de conexão entre eles para determinar a existência de uma comunidade. A Figura 1.1 ilustra o roteiro do minicurso, cujo foco está no processamento e detecção de câmaras de eco em redes sociais.

O restante do capítulo está estruturado conforme expresso a seguir. A Seção 1.2 descreve a metodologia utilizada. A Seção 1.3 define o fenômeno das câmaras de eco e o diferencia dos tópicos relacionados. As abordagens atuais de detecção de câmaras de eco são discutidas na Seção 1.4. As estratégias de criação de uma base de dados para identificação correta de câmaras de eco são apresentadas na Seção 1.5. A Seção 1.6 descreve como as câmaras de eco podem ser estruturadas, modeladas e caracterizadas utilizando conceitos de redes complexas. As Seções 1.7 e 1.8 explicam os processos para a transformação de textos e grafos em matrizes operáveis computacionalmente, respectivamente. Na Seção 1.9.1 são apresentados os principais algoritmos de detecção de comunidade na literatura para identificar câmaras de eco. A Seção 1.10 elenca os desafios e as soluções focadas no combate de câmaras de eco. A Seção 1.11 apresenta uma atividade prática de identificação de câmaras de eco. A Seção 1.12 realiza as considerações finais do trabalho.

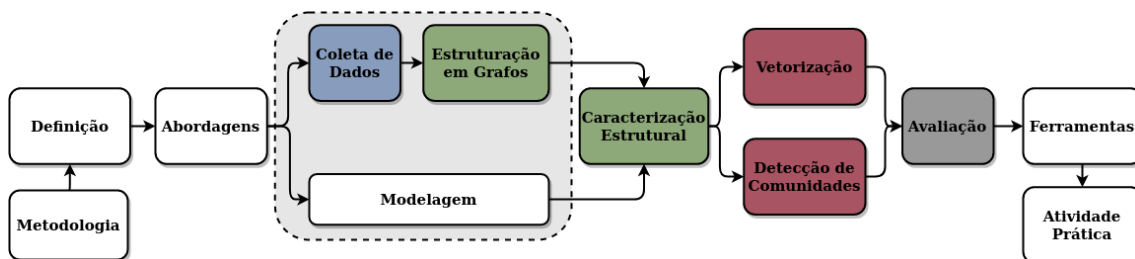


Figura 1.1. Fluxograma do roteiro do minicurso. Visando apresentar em detalhes o processamento e detecção de câmaras de eco sob uma perspectiva em grafos, o minicurso inicia relatando a metodologia adotada. Depois apresenta-se a definição de câmaras de eco seguida das diferentes abordagens de detecção da mesma. Posteriormente, debate-se que o estudo das câmaras de eco pode ser feito através de modelagem ou utilizando dados reais coletados e estruturados em grafos. Em seguida, descreve-se as principais métricas para caracterização das câmaras de eco, bem como os métodos de vetorização e algoritmos de detecção de comunidade. Além disso, são discutidas métricas de avaliação intrínsecas e extrínsecas. Vale ressaltar que a atividade prática aborda todas as etapas descritas neste roteiro, exceto aquelas em branco.

1.2. Metodologia

Neste minicurso, utiliza-se a metodologia PRISMA⁶ (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*) para realizar uma revisão sistemática da literatura a fim de identificar e recuperar estudos relevantes publicados em periódicos revisados por pares e anais de conferências.

A pesquisa bibliográfica é conduzida através de uma busca por palavras-chave claramente definidas na base de dados acadêmicos *online Dimensions*⁷. A escolha do *Dimensions* justifica-se pela sua capacidade de oferecer uma cobertura temporal e de fonte de publicação mais ampla do que o *Scopus* e *Web of Science* na maioria das áreas, sendo equiparável em cobertura ao *Google Scholar*. O levantamento inicial foca em buscas booleanas usando as palavras-chave: “*echo chamber*”, em combinação com (AND) “*social media*” (OR) “*social network*”. Buscando-se correspondências do conjunto de palavras-chaves escolhido nos títulos e resumos dos estudos, a ferramenta retorna 501 resultados. Todos os resultados são submetidos ao processo de avaliação de elegibilidade detalhado no diagrama de fluxo da metodologia PRISMA mostrado na Figura 1.2. Uma vez identificados, os 500 títulos são submetidos a uma etapa de triagem, onde são removidos eventuais duplicatas (n=28), selecionando os 472 estudos únicos. Ainda analisando os títulos e os resumos na etapa de triagem, uma segunda remoção é desempenhada com base nos seguintes critérios de exclusão: i) conteúdo não escrito na língua inglesa (n=18); ii) capítulos de livro, livros, monografias e artigos curtos (n=77); iii) publicação em revistas ou conferências de áreas outras áreas do conhecimento, tais como ciência política, jornalismo ou psicologia (n=197). Fundamentado-se nesses critérios de exclusão, apenas 180 artigos prosseguiram para uma verificação mais detalhada, na qual o texto completo de cada artigo é avaliado. Nesta etapa, são igualmente excluídos artigos sem acesso aberto (n=52) e artigos cuja proposta não é diretamente relacionada à câmaras de eco (n=53).

⁶Disponível em <https://www.prisma-statement.org/>.

⁷Disponível em <https://www.dimensions.ai/>.

Dessa verificação em profundidade restam 75 estudos aptos a serem analisados qualitativamente. Contudo, por questões de espaço, este minicurso seleciona e analisa 30 artigos.

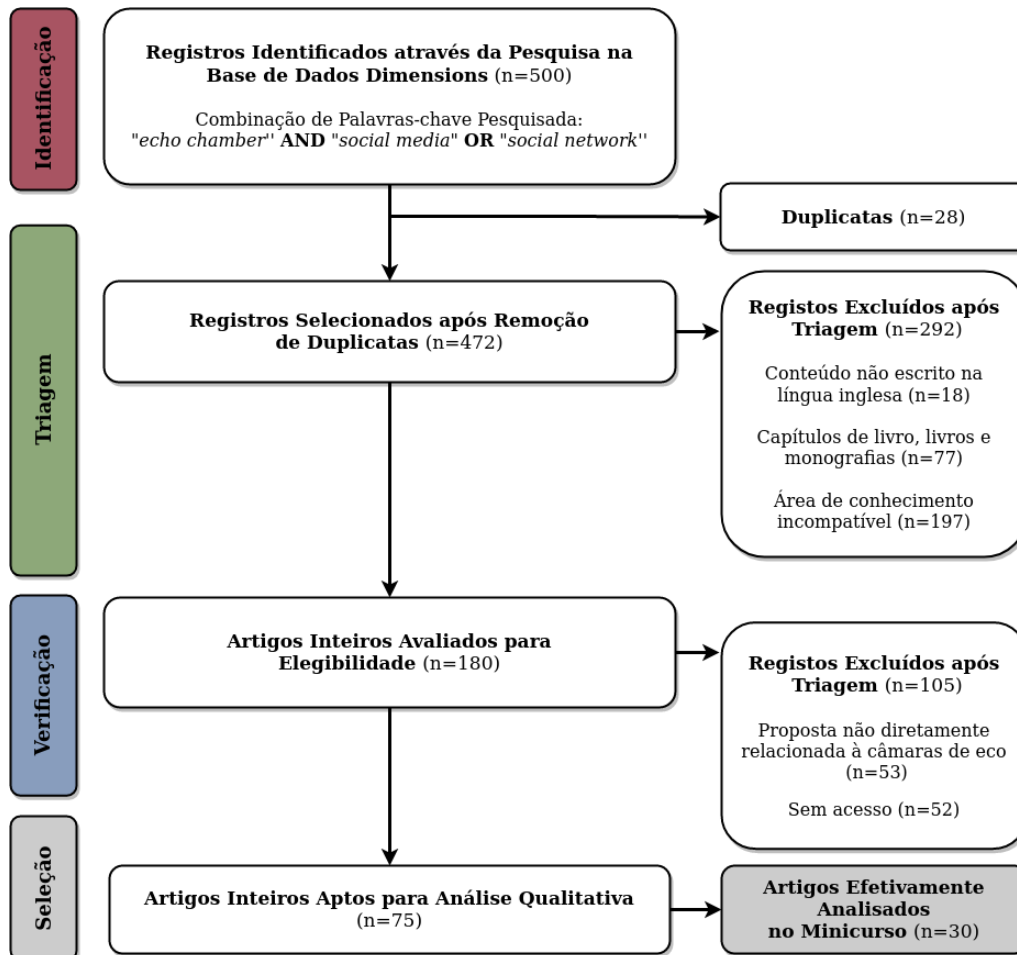


Figura 1.2. Fluxograma da metodologia Prisma aplicada ao tema abordado no minicurso: câmaras de eco. Para formar um conjunto inicial de artigos a respeito do tema, realiza-se uma pesquisa bibliográfica na base de dados Dimensions utilizando palavras-chaves específicas. Seguindo vários critérios de exclusão, seleciona-se apenas os artigos científicos publicados em inglês e estritamente alinhados com o tema e com metodologias computacionais.

1.3. Caracterização das Câmaras de Eco

As câmaras de eco não possuem uma definição única e consensual na literatura. Apesar da multiplicidade de definições, em um sentido mais amplo, *as câmaras de eco são definidas como uma rede ativa de usuários, na qual ideias semelhantes são amplificadas ou reforçadas por meio de um processo de compartilhamento repetitivo de uma mesma ideia, blindando-a de refutação* [Morini et al., 2021]. Diante dessa definição, caracteriza-se uma câmara de eco em relação a três aspectos: i) a composição estrutural, ii) o conteúdo divulgado e iii) o comportamento de seus integrantes perante refutação. Nas redes sociais *online*, as câmaras de eco organizam-se na forma de uma rede de comunicação altamente conectada, composta por diferentes tipos de usuários, porém com posicionamentos ideológicos semelhantes. Dentro das câmaras de eco, há uma preva-

lência pelo compartilhamento de conteúdos extremamente unilaterais e muito aderentes às posturas e opiniões dos usuários que a integram. Essa ressonância de informação no interior de câmaras de eco é igualmente acompanhada por uma tática ativa de descredibilização e exclusão de quaisquer fontes ou opiniões externas ou divergentes. Na prática, quando expostos a fatos que desafiam suas crenças, os membros de câmaras de eco rapidamente os rejeitam já que não fortalecem seus posicionamentos originais. Tal atitude reativa a contra-evidências é descrita pelo efeito *backfire* [Alatawi et al., 2021], que resulta em membros acreditarem em informação ilegítima, mesmo após a apresentação de evidências de inverdades.

A definição de câmara de eco confunde-se comumente com a de outro fenômeno relacionado, a **bolha de filtro** (*filter bubble*). Embora a bolha de filtro também restrinja o acesso à informação de seus integrantes, o isolamento observado nas bolhas de filtro é derivado do uso de um conjunto extremamente restrito de recomendações. Normalmente, essas sugestões são automaticamente realizadas pelos chamados sistemas de recomendação, empregados em redes sociais *online*. Esses sistemas de recomendação consistem em algoritmos que inferem os interesses ou preferências do próprio usuário por meio da análise de dados subjacentes ao uso da rede, tais como comportamento de cliques, histórico de compras ou registro de pesquisas [Ge et al., 2020]. Como a superabundância de informações seria esmagadora para qualquer usuário, os sistemas de recomendação têm o papel fundamental de personalizar o fluxo de informações, selecionando e exibindo somente o conteúdo mais relevante para cada usuário. As redes sociais exigem uma quantidade adequada de diversidade para permitir a soberania informacional de seus usuários. No entanto, a imposição de filtros personalizados nas informações pode exacerbar a fragmentação, criando ciclos de *feedback* degenerados, nos quais a amplitude da informação é cada vez mais reduzida ao longo do tempo [Donkers e Ziegler, 2021].

Comparativamente, a bolha de filtro apresenta uma estrutura relativamente mais frágil que a câmara de eco, uma vez que são permissivas a fontes externas relevantes. Ao contrário da descredibilização adotada nas câmaras de eco, as fontes externas são normalmente ignoradas por motivos involuntários do usuário. Diferentemente das câmaras de eco, a exposição dos usuários em bolhas de filtro a informações ou argumentos relevantes, não experienciados antes, permite libertá-los de suas bolhas [Nguyen, 2020]. Embora menos potencialmente danosas, a superpersonalização intencional de uma bolha de filtro pode eventualmente confinar usuários em câmaras de eco. Outro termo relacionado, o **gatekeeping**, traduz-se como uma prática de filtragem de informação tradicionalmente executada por fontes midiáticas. Quando essa prática é executada por usuários, esses passam a ser intitulados como *gatekeepers*. Os *gatekeepers* consomem conteúdo de múltiplas visões ideológicas, porém reproduzem ou disseminam conteúdos relacionados a uma única visão [Garimella et al., 2018a].

A organização dos usuários em grupos homogêneos está intimamente atrelada ao conceito de **homofilia**, ou seja, a tendência dos indivíduos de se associarem a outros semelhantes. Essa semelhança ou similaridade social pode ser classificada em: i) homofilia de *status*, relacionada ao agrupamento de pessoas com base em suas características semelhantes atribuídas (sexo, raça ou etnia) ou adquiridas (educação ou religião); e ii) homofilia de valor, que envolve agrupar pessoas semelhantes com base em seus valores, atitudes ou crenças. Dependendo da ideologia atrelada, a câmara de eco pode ser for-

mada devido à homofilia de *status*, homofilia de valor ou ambos. As plataformas de redes sociais afrouxaram as fontes básicas de homofilia, como a geografia, permitindo que os usuários vinculem relacionamentos homófilos em outras dimensões, como raça, etnia, sexo, gênero e religião [Colleoni et al., 2014, Alatawi et al., 2021].

As câmaras de eco podem tornar os usuários de mídia social mais vulneráveis a esse tipo de manipulação. A estrutura da câmara de eco pode contribuir para a disseminação de **notícias falsas** de diversas formas. Em câmaras de eco, as pessoas são repetidamente expostas a informações homogêneas. Além disso, a seleção de informações consistentes com as crenças e a prevenção de informações contrárias ou contrastantes às crenças reforçam a confiança nas opiniões minoritárias, como notícias fabricadas, mesmo na presença de evidência contrária preponderante. A estrutura da câmara de eco também induzir a uma convergência rápida e prematura para soluções sub-ótimas de problemas complexos. Ademais, o limiar para perceber um conteúdo como novo pode ser menor dentro das câmaras de eco em virtude da reduzida diversidade de pontos de vista aos quais as pessoas estão expostas. As tentativas de captura de atenção são desempenhadas pelo uso de conteúdo inflamatório, polêmico, ou emocional.

Além das notícias falsas, as câmaras de eco criam uma estrutura que potencializa a crença de que alguma organização secreta, mas influente, se reúne em acordo secreto a fim de alcançar um objetivo malévolo. Na prática, as **teorias conspiratórias** são tentativas de explicar as causas finais de eventos e circunstâncias sociais e políticas significativas. Seus adeptos usam as redes sociais para se encontrarem, disseminarem conteúdos conspiratórios e compartilharem pontos de vista marginais. As teorias da conspiração expressam e amplificam ansiedades e medos de perder o controle da ordem religiosa, política ou social. Na literatura científica, diversos trabalhos debruçam-se sobre o estudo das câmaras de eco considerando a disseminação de teorias conspiratórias em seu interior [Del Vicario et al., 2016, Bessi, 2016]. Com o objetivo de esclarecer e evitar o intercambiamento equivocado, a Tabela 1.1 condensa as definições dos principais termos e conceitos associados às câmaras de eco.

1.3.1. Trabalhos Relacionados

Na literatura científica, o estudo de câmaras de eco é frequentemente associado a outros assuntos relacionados, dentre eles: a controvérsia ou polarização ideológica, a disseminação de conteúdo falso, a modelagem de opinião, a homofilia e sistemas de recomendação. Dentre esses trabalhos, Cossard *et al.* analisam no *Twitter* o debate sobre vacinação tendo como premissa a existência de câmaras de eco [Cossard et al., 2020]. Ao caracterizar e distinguir usuários em grupos de acordo com seus posicionamentos defensivo ou cético sobre vacinas, as características relacionais e textuais aplicadas a algoritmos de classificação. Resultados qualitativos apontam que céticos e os defensores da vacinação residem em suas próprias câmaras de eco e têm preferências por fontes de informação excludentes entre si. Visando promover a redução da controvérsia em redes sociais, Garimella *et al.* investigam técnicas algorítmicas para interligar usuários de câmaras de eco isoladas [Garimella et al., 2017]. Ao empregar uma métrica de quantificação de controvérsias, o modelo proposto busca pelas chamadas pontes, conexões entre usuários que minimizem essa métrica. Partindo da hipótese de que usuários localizados na borda de uma câmara de eco estão menos fechadas à diferentes opiniões, espera-se que conteúdos

Tabela 1.1. Definições dos termos e conceitos associados à câmaras de eco.

Termos	Definição
Câmaras de Eco	Estruturas sociais que excluem sistematicamente as fontes de informação não necessariamente por omissão, mas por ação deliberada.
Bolha de Filtro	Ambiente social superpersonalizado derivado da filtragem excessiva de informação, praticada automaticamente por sistemas de recomendação.
Sistemas de Recomendação	Algoritmos que inferem os interesses ou preferências do próprio usuário por meio da análise de dados subjacentes ao uso da rede, exibindo em um conteúdo personalizado.
<i>Gatekeeping</i>	Prática de filtragem de informação tradicionalmente executada por fontes de mídia.
Homofilia	Conceito psicológico relacionado à tendência dos indivíduos de se associarem a outros com características ou valores semelhantes.
Viés de Confirmação	Conceito psicológico relacionado à tendência dos indivíduos procurarem e privilegiarem o recebimento de informações que refiram seus pontos de vista existentes.
Notícias Falsas	Notícias comprovadamente inverídicas, criadas e disseminadas intencionalmente para confundir ou desacreditar algo ou alguém.
Teorias de Conspiração	Crença na existência de que alguma organização secreta, mas influente, se reúne em acordo secreto a fim de alcançar um objetivo malévolo.

enviados de fora da câmara de eco possam ser recebidos e eventualmente endossados pelo usuário que a recebeu.

Ge *et al.* investigam a formação e os efeitos de câmaras de eco em sistemas de recomendação de plataformas *e-commerce* [Ge et al., 2020]. Empregando uma base de dados real formada pelo histórico de acesso *web* dos usuários, os autores distinguiram esses usuários em grupos com base na frequência que estes aceitam, ou ignoram, produtos recomendados. A análise temporal dos resultados sugere que as câmaras de eco apresentam um impacto maior sobre o comportamento de clique do usuário, enquanto que têm sua influência mitigada sobre comportamentos de compra. Tentando prevenir a superpersonalização dos sistemas de recomendação, Dash *et al.* apresentam um *framework* baseado em redes para auditar de sistemas de recomendação [Dash et al., 2019]. Em particular, os autores quantificam duas propriedades principais, a diversidade das recomendações fornecidas pelos sistemas de recomendação e o grau de segregação e polarização de informações fornecidas aos usuários. A proposta é especialmente adequada para uso por auditores terceirizados, uma vez que independe da disponibilidade de informações sobre a interação entre usuário e item. Com um objetivo mais específico, Cinus *et al.* visam avaliar a contribuição dos sistemas de recomendação de pessoas no aumento ou diminuição das câmaras de eco [Cinus et al., 2022]. Diferentemente dos tradicionais, os sistemas de recomendação de pessoas dedicam-se à geração de sugestões de amizade contendo pessoas

que compartilham os mesmos interesses, ou o mesmo grupo de amigos, que o usuário. Ao combinar um modelo de dinâmica de opinião com um algoritmo de recomendação de pessoas, a proposta é capaz de simular o comportamento de indivíduos mudando de opinião como consequência de suas interações com sua vizinhança. Resultados mostraram que, caso haja uma homofilia inicial considerável na rede, as recomendações de pessoas podem efetivamente contribuir para a inclusão de novos usuários em câmaras de eco.

Outros trabalhos visam traçar relações de causa e efeito entre câmaras de eco e disseminação de conteúdo falso. Com esta finalidade, Törnberg modela a disseminação de notícias falsas nas mídias sociais atribuindo a cada usuário um limite que descreve o quão difícil é convencê-lo sobre uma determinada narrativa [Törnberg, 2018]. Caso uma fração suficientemente grande de seus vizinhos espalhe um mesmo conteúdo, o usuário é convencido e replicará a o conteúdo. O modelo revela que as notícias originadas no interior de câmaras de eco têm uma maior disseminação do que quando comparado a uma rede sem grupos definidos. Além disso, mostra-se que a simples reunião de usuários com visões homogêneas pode ser suficiente para aumentar a prevalência de desinformação, tendo em vista que a viralidade é diretamente proporcional à homofilia da rede. De forma similar, Bessi *et al.* conduzem uma análise quantitativa minuciosa para investigar a consumo e propagação de diferentes assuntos de teorias da conspiração dentro de câmaras de eco no *Facebook* [Bessi et al., 2015]. Ao coletar e analisar as curtidas, compartilhamentos e comentários dos usuários, revela-se que os diferentes assuntos conspiratórios são consumidos de maneira semelhante pelos usuários de câmaras de eco. A única divergência está no tempo de atividade, ou seja, o intervalo temporal entre o primeiro e o último comentário de cada usuário. Em especial, usuários polarizados em assuntos relacionados à geopolítica são mais ativos nos comentários.

Em contrapartida, a modelagem psico-linguística explora as cinco dimensões básicas que compõem a personalidade humana para identificar o comportamento dos indivíduos envolvidos em narrativas de apoio dentro de câmaras de eco. As cinco dimensões básicas são: extroversão, estabilidade emocional, amabilidade, consciência e abertura. Uma das abordagens existentes, intitulada reconhecimento de personalidade não supervisionada, executa uma série de correlações estatisticamente significativas entre os traços de personalidade e as características linguísticas extraídas por meio de técnicas de Processamento de Linguagem Natural (PLN) [Bessi, 2016].

1.4. Abordagens de Detecção de Câmaras de Eco

Atualmente, as abordagens de detecção de câmaras de eco distinguem-se em duas grandes classes de abordagens, a baseada em ideologia e a baseada em topologia de rede. A **abordagem baseada na ideologia** infere a existência de um ambiente virtual polarizado ao analisar semanticamente a inclinação do conteúdo compartilhado ou consumido por um usuário [Alatawi et al., 2021]. Internamente, essa análise semântica visa medir a similaridade, ou distância, entre representações vetoriais do texto compartilhado, seja esse derivado de comentários, postagens, notícias ou mensagens. Tais representações vetoriais podem ser obtidas por meio de modelos simples como Frequência do Termo – Inverso da Frequência nos Documentos (*Term Frequency–Inverse Document Frequency*, TF-IDF), ou por meio de algoritmos de incorporação de palavras (*word embeddings*), que empregam redes neurais treinadas com grandes volumes de dados textuais. Algoritmos

como *GloVe* e *Word2Vec* são capazes de embutir a semântica das palavras em vetores de baixa dimensão, densos e de tamanho fixo, garantindo que sinônimos ou palavras minimamente relacionadas sejam mapeados em vetores similares [de Oliveira et al., 2021b]. Essa representação vetorial individualizada das palavras é especialmente empregada na detecção de notícias falsas, um conteúdo frequentemente divulgado em câmaras de eco.

A detecção de câmaras de eco segundo a **abordagem baseada em topologia de rede** explora os padrões de propagação de conteúdo entre os usuários. Normalmente, a abordagem topológica inicia com a extração de metadados de usuários participantes de um debate controverso nas redes sociais. Em posse dos metadados, é possível inferir os posicionamentos de cada usuário a respeito do tópico selecionado, bem como construir estruturas em grafos que representem as interações digitais entre eles. Dentre as vantagens dessa estruturação em redes de usuários estão: i) a possibilidade de revelar padrões estruturais característicos de câmaras de eco por meio de métricas de redes complexas; e ii) a identificação de grupos de usuários homogêneos a partir da aplicação de algoritmos de detecção de comunidades [Alatawi et al., 2021].

Morini *et al.* introduzem a visão de classificação das câmaras de eco de acordo com a escala da detecção. Nessa visão, as chamadas câmaras de eco de **microescala** são delimitadas avaliando o comportamento online de usuários singularmente, fato que acarreta a perda de sua dimensão agregada. Alternativamente, as câmaras de eco de **macroescala** são delimitadas considerando a rede de interação dos usuários em um nível mais amplo, ou seja, analisando o grafo como um todo. Contudo, este tipo de câmara de eco pode ignorar eventuais diferenças dentro de determinadas áreas da rede. Uma terceira classificação expressa que as câmaras de eco de **mesoescala** podem ser identificadas como apenas um subconjunto de nós na rede geral. Isso implica que, na rede geral de debates, é possível encontrar diversas câmaras de eco com a mesma inclinação ideológica [Morini et al., 2021]. A Tabela 1.2 apresenta vários trabalhos relacionados ao estudo de câmaras de eco, distinguindo-os segundo a abordagem adotada e o tipo da câmara de eco detectada.

1.5. Construção da Base de Dados

A construção de uma base de dados potencialmente relacionada às câmaras de eco inicia-se com a seleção de um tópico controverso. Independente do domínio de conhecimento, a discussão sobre questões duais propiciam a polarização de opiniões e podem transformar atitudes divergentes em extremos ideológicos. Questões controversas são igualmente debatidas tanto no âmbito *offline* quanto no *online*. Contudo as plataformas de redes sociais *online* são provavelmente o espaço aberto mais utilizado para discussões. Essas plataformas possuem estrutura e funcionalidades que facilitam a identificação de debates *online* sobre uma ampla gama de questões diferentes. Plataformas como o *Twitter*, *Instagram* e *Facebook* permitem que os usuários incluam em suas postagens *hashtags*, que são palavras, ou frases sem espaçamento, prefixadas com o caractere cardinal “#”. Embora tenham sido originalmente idealizadas para indexar as postagens dos usuários, as *hashtags* atualmente comportam-se como um termômetro de eventos sociopolíticos, comerciais e culturais. Visto que as *hashtags*, assim como qualquer outra manifestação textual, expressam os interesses, opiniões e crenças dos seus autores, elas podem ser usadas como ponto de partida para encontrar grupos de usuários com posici-

Tabela 1.2. Trabalhos relacionados à modelagem, caracterização, quantificação ou detecção de câmaras de eco.

	Abordagem		Tipo de Câmara de Eco		
	Topológica	Ideológica	Microescala	Mesoescala	Macroescala
[Bakshy et al., 2015]	✗	✓	✓	✗	✗
[Zollo et al., 2017]	✗	✓	✗	✗	✓
[Morini et al., 2021]	✓	✓	✗	✓	✗
[Conover et al., 2011]	✓	✓	✗	✗	✓
[Barberá et al., 2015]	✓	✓	✗	✗	✓
[Cossard et al., 2020]	✓	✓	✗	✗	✓
[Villa et al., 2021]	✓	✓	✗	✗	✓
[Williams et al., 2015]	✓	✓	✗	✗	✓
[Sasahara et al., 2021]	✓	✗	✗	✗	✓
[Bessi, 2016]	✗	✓	✗	✗	✓
[Garimella et al., 2018a]	✓	✓	✗	✗	✓
[Morales et al., 2021]	✓	✓	✗	✗	✓
[Cinelli et al., 2021]	✓	✓	✗	✗	✓
[Zannettou et al., 2018]	✗	✓	✗	✗	✓
[Cota et al., 2019]	✓	✗	✗	✗	✓
[Baumann et al., 2020]	✓	✗	✗	✗	✓
[Gillani et al., 2018]	✓	✗	✗	✗	✓

onamentos semelhantes sobre um determinado assunto. De forma diferente, plataformas como *Reddit* e *Gab* são organizadas como fóruns virtuais que restringem o debate por temas de interesse, tirando o foco das *hashtags*. No *Reddit* tais comunidades de interesse são chamadas *subreddits*. Para coletar os dados oriundos dessas redes de forma automática, algumas plataformas disponibilizam APIs, como o *Twitter*⁸. Além de utilizar a API própria da plataforma, é possível utilizar códigos terceirizados desenvolvidos no formato de APIs, como no caso do *Reddit* e do *Gab*⁹. A Tabela 1.3 traz uma compilação de bases de dados presentes na literatura sobre câmaras de eco ou qualquer tópico relacionado, como polarização política e bolhas de filtro.

1.6. Estruturação e Modelagem de Câmaras de Eco

A Análise de Redes Sociais (*Social Network Analysis* - SNA) compreende a investigação de relações ou fenômenos sociais por meio do uso de grafos, que são estruturas matemáticas compostas por vértices e arestas. Um grafo $\mathcal{G} = (\mathcal{V}, \mathcal{E})$ possui $|\mathcal{V}|$ vértices (ou nós) interligados por $|\mathcal{E}|$ arestas. Os grafos são orientados quando a relação entre dois nós é unidirecional e, portanto, para que $v_i \in \mathcal{V}$ esteja conectado a $v_j \in \mathcal{V}$ e v_j esteja conectado a v_i devem existir duas arestas $\{\varepsilon_{i,j}, \varepsilon_{j,i}\} \in \mathcal{E}$. Se o grafo é não orientado, a relação entre os nós é bidirecional, e apenas uma aresta $\varepsilon_{i,j} \in \mathcal{E}$ precisa existir entre v_i e v_j para que estejam conectados entre si. As arestas, sejam bidirecionais ou unidirecionais, podem possuir pesos não unitários $w_{i,j} \in \mathcal{W}$, transformando os grafos em grafos ponderados $\mathcal{G} = (\mathcal{V}, \mathcal{E}, \mathcal{W})$. Os pesos representam a intensidade da ligação entre os pares de nós adjacentes.

⁸Disponível em <https://developer.twitter.com/en/docs/twitter-api>.

⁹Disponível em <https://github.com/pushshift/api>.

Tabela 1.3. Base de dados

	Plataforma	Tópico	#P	#U	Período
[Bessi, 2016]	Facebook	Ciência e Teorias Conspiratórias	3M	30k	2010-2014
[Del Vicario et al., 2016]	Facebook	Ciência e Teorias Conspiratórias	271k	ND	2010-2014
[Garimella e Weber, 2017]	Twitter	Orientação Política	ND	140M	2009-2016
		Orientação Política	2 bi	679k	2007-2016
[Garimella et al., 2018a]	Twitter	Controle de Armas	19M	7.5k	2016
		Política de Saúde (<i>obamacare</i>)	39M	8.7k	2015
		Legalização do Aborto	34M	3.9k	2016
[Cossard et al., 2020]	Twitter	Vacinação	818k	102k	2018-2019
[Cota et al., 2019]	Twitter	Orientação Política	12M	285k	2016
[Gillani et al., 2018]	Twitter	Orientação Política	ND	1.1M	2016
[Barberá et al., 2015]	Twitter	Política, Esporte e Entretenimento	150M	3.8k	2012-2014
[Morini et al., 2021]	Reddit	Orientação Política	431k	72k	2017-2019
		Controle de Armas	180k	65k	
		Discriminação de Minorias	223k	52k	
[Cinelli et al., 2021]	Reddit	Orientação Política	353k	240k	2017
	Reddit	Personalidade (<i>the donald</i>)	1.2M	138k	
	Reddit	Notícias	723k	179k	
	Gab	ND	13M	165k	
[Zannettou et al., 2018]	Gab	ND	22M	336k	2016-2018

#P representa o número de postagens.

#U representa o número total de nós.

ND representa informações não disponibilizadas pelos autores.

As redes sociais *online* são representadas e modeladas matematicamente como redes complexas, *i.e.*, grafos detentores de um grande número de nós e interligados por meio de uma topologia complexa, podendo esses grafos serem orientados ou não, dependendo do tipo de relação entre os nós. Por exemplo, em uma rede social como *Twitter* ou *Instagram* os grafos que representam a conexão entre pessoas é orientado. A pessoa v_i pode seguir a pessoa v_j sem que a pessoa v_j siga a pessoa v_i , existindo, assim, apenas a

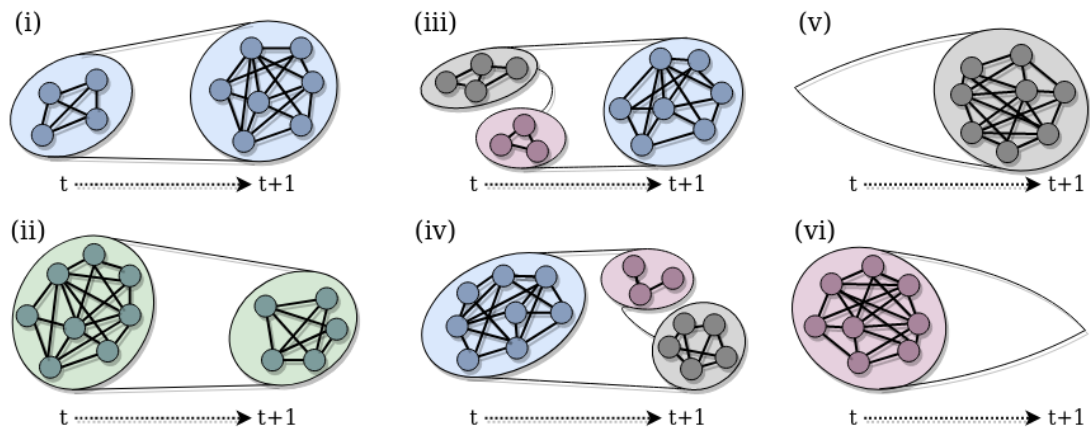


Figura 1.3. Principais eventos na evolução de comunidades ao longo do tempo: (i) crescimento, (ii) contração, (iii) mesclagem, (iv) divisão, (v) nascimento e (vi) morte. Adaptado de [Barabási, 2016].

aresta $\varepsilon_{i,j}$. Isso implica que v_i recebe o conteúdo de v_j , mas o inverso não é verdade. Em uma rede social como *Facebook*, para que duas pessoas estejam conectadas, elas precisam ser amigas uma da outra, de forma que há uma relação bidirecional entre todos os nós que fazem parte dessa rede. Assim, o grafo da rede para essa representação de conexão entre pessoas é não orientado e todas as arestas representam uma relação bidirecional em que v_i recebe conteúdo de v_j e vice-versa.

O problema abstrato de identificar câmaras de eco em redes sociais é tratado na abordagem topológica como um problema de identificar comunidades em um grafo. Na teoria de redes complexas, define-se uma comunidade como um subconjunto de nós densamente conectados entre si e esparsamente conectado aos demais nós [Yang et al., 2016, Terren e Borge-Bravo, 2021]. Em uma rede estática, a topologia não se altera ao longo do tempo, facilitando a aplicação direta de algoritmos clássicos de detecção de comunidades. Porém, essa estruturação estática não é suficientemente capaz de retratar a natureza evolutiva de sistemas reais, como a criação de novos vínculos com outras pessoas e a extinção de antigos vínculos, o que representaria, por exemplo, novas amizades e o término de antigas amizades. Assim, devido à dinamicidade das redes sociais, a topologia da rede varia ao longo do tempo e a rede estática não é a melhor representação. Nesse sentido, é válido utilizar representação de redes temporais para modelar a rede social em observação. As redes temporais têm uma topologia variável no tempo, em que nós e arestas podem estar ativos ou não, dependendo do instante de observação. Ao lidar com redes temporais, seis principais eventos podem ocorrer com as comunidades entre os tempos de observação t e $t + 1$, conforme retratado na Figura 1.6. O (i) Crescimento ocorre quando há um aumento do tamanho de uma comunidade entre os tempos de observação. A (ii) Contração ocorre se houver diminuição do tamanho da comunidade. Duas ou mais comunidades podem ser unidas, incorrendo o evento de (iii) Mesclagem. De forma contrária, uma comunidade pode ser separada em duas ou mais comunidades pelo evento da (iv) Divisão. Por fim, podem ocorrer o (v) Nascimento, quando uma comunidade aparece pela primeira vez, e a (vi) Morte quando uma comunidade desaparece.

Existem três modelos principais para representação de redes temporais:

- **Sequência de Contato**, redes cujas arestas existem por um tempo desprezível e são representadas como um conjunto de sequência de contato (i, j, t) em que i e j são nós, t é o carimbo de tempo do contato;
- **Grafo de Intervalo**, redes que registram a duração dos períodos de atividade da uma aresta e através um conjunto de intervalos $T_e = (t_1, t'_1) \dots (t_n, t'_n)$;
- **Instantâneo**, rede segmentada em uma série de janelas de tempo sequenciais (e.g. *snapshot*) em que contatos em uma janela de tempo são agregados em arestas. A evolução da rede temporal pode ser estudada através desses *snapshots*.

Embora as redes temporais de **sequência de contato** e **grafo de intervalo** preservem as informações temporais, esses modelos têm uma análise mais complexa e dependem da aplicação de novas metodologias e algoritmos. A rede temporal representada por **instantâneo** reduz a complexidade da análise, permitindo o uso de métodos de pesquisa de redes estáticas de forma independente em cada *snapshot*. Contudo, a principal limitação do modelo instantâneo é a indeterminação quanto ao tamanho ótimo do grafo para quaisquer análises. Na prática, a escolha do tamanho adequado depende de uma profunda compreensão da rede em questão, sendo vital para evitar a particularização da análise e a obtenção de resultados dissonantes. *Snapshots* muito curtos podem não conter arestas suficientes agregadas em cada instantâneo, resultando em informações incompletas. Por outro lado, o uso de *snapshots* muito longos pode mascarar detalhes da evolução do grafo [Rossetti e Cazabet, 2018].

Mediante a coleta de dados, muitos autores costumam estruturar as câmaras de eco aproveitando-se dos dados nativos extraídos das plataformas de redes sociais. Com o *Twitter*, por exemplo, pode-se empregar metadados descorrelacionados como *retweets*, menções e seguidores para construir grafos relacionais. Esses grafos representam redes semânticas em que os nós descrevem um determinado padrão e as arestas descrevem a relação entre os nós, ou seja, a relação entre os padrões [Meyer-Baese e Schmid, 2014]. Assim, as interações usuário-usuário, como seguir, repostar, bater papo e comentar entre si, podem ser utilizadas para desvendar a difusão de informações e a relação entre os usuários das redes sociais *online*. Uma rede de *retweets* pode ser reproduzida através de um grafo relacional direcionado ponderado em que os nós representam o conjunto de usuários distintos e o peso de uma aresta do nó v_i ao nó v_j representa o número de vezes que o usuário v_i reposta um *tweet* do usuário v_j . Essa mesma lógica pode ser adotada com plataformas que também disponibilizam o número de curtidas (*likes*) nas postagens, como o *Facebook*. Similarmente, uma rede de menção pode ser retratada por um grafo relacional direcionado ponderado na qual os nós representam os usuários e as arestas representam as menções, ou seja, a ação de incluir um nome de usuário em um *tweet*. O peso de uma aresta do nó v_i ao nó v_j representa o número de vezes que o usuário v_i menciona o usuário v_j . Finalmente, a rede de seguidores pode ser construída por meio de um grafo relacional direcional na qual os nós representam usuários e uma aresta do nó v_i ao nó v_j representa o usuário v_i seguindo o usuário v_j .

1.6.1. Métricas de Redes Complexas em Comunidades

O mapeamento das redes sociais em grafos permite interpretar cada câmara de eco como uma comunidade, podendo assim revelar características estruturais latentes dessas

câmaras a partir de métricas de redes complexas. Para o cálculo da maioria das métricas de redes complexas é necessário conhecer os conceitos de caminho, passeio, passeio aleatório e clique. Um caminho é definido como uma sequência ordenada de arestas que unem nós adjacentes, sem repetição dos nós. O tamanho desse caminho é definido pelo número de arestas atravessadas. O caminho mais curto, $\delta_{i,j}^*$, entre um par de nós é aquele que atravessa o menor número de arestas possível. De forma semelhante, um passeio também é uma sequência ordenada de arestas que unem nós adjacentes. Contudo, em um passeio, não há restrição quanto à repetição de nós e de arestas na sequência ordenada. Já um passeio aleatório é definido como um processo aleatório que parte de um nó inicial com destino a um nó final. Em cada nó a partir do nó inicial, há uma determinada probabilidade de seguir para um dos nós adjacentes ao nó atual. Ao alcançar o nó final, existe uma sequência ordenada de arestas que atravessa o grafo partindo do nó inicial até o nó final. A essa sequência gerada pelo processo aleatório dá-se o nome de passeio aleatório. Assim como no passeio tradicional, pode haver repetição de vértices e arestas. Por fim, um clique é um subconjunto de nós de um grafo não direcionado em que quaisquer dois nós distintos desse subconjunto são sempre adjacentes, isto é, o subconjunto de nós é totalmente conectado, formando uma malha completa.

Métricas comumente utilizadas na análise de comunidades são a densidade, o diâmetro, a assortatividade, e as diversas variações de centralidades [de Oliveira et al., 2021a]. A densidade de um grafo, $D(\mathcal{G})$, indica quão denso um grafo é em termos de conectividade de arestas e é medida em função do número total de arestas $|\mathcal{E}|$ e nós $|\mathcal{V}|$ pertencentes ao grafo, conforme Equação 2. O diâmetro é expresso pela máxima excentricidade do grafo, ou seja, o maior dentre todos os caminhos mais curtos existentes entre todos os pares de nós v_i e v_j , cujo comprimento é dado por $\delta^*(v_i, v_j)$, em número de saltos. Matematicamente, a excentricidade $e(\mathcal{G})$ é dada pela Equação 3. Assim, o diâmetro, $d(\mathcal{G})$, de um grafo, dado pela Equação 2, pode assumir valores inteiros no intervalo de $[1, \infty[$.

$$D(\mathcal{G}) = \frac{2|\mathcal{E}|}{|\mathcal{V}| \cdot (|\mathcal{V}| - 1)} \quad (1) \quad d(\mathcal{G}) = \max_{v_i \in \mathcal{V}} e(v_i) \quad (2)$$

$$e(v_i) = \max_{v_j \in \mathcal{V}} \delta^*(v_i, v_j) \quad (3)$$

Quando transportado para o âmbito de redes complexas, o conceito de homofilia é representado pela métrica de assortatividade. Essa métrica, definida entre $[-1, 1]$, expressa a tendência de nós se conectarem a outros nós com valores semelhantes de uma determinada característica. Ao considerar o grau como característica a ser avaliada, por exemplo, valores positivos de assortatividade indicam uma correlação entre nós de grau semelhante, enquanto valores negativos indicam relações entre nós de grau diferente. Valores nulos traduzem a completa conexão entre todos os nós em um grafo. Casos extremos, positivos ou negativos, mostram que o grafo exhibe padrões de mistura entre ordenamentos perfeitos ou padrões não ordenados, respectivamente [de Oliveira et al., 2021a, Wandelt et al., 2020]. Adicionalmente, as diversas variações de centralidade visam quantificar a importância de cada nó em um grafo. Essa importância assume

diferentes sentidos dependendo do tipo de centralidade. Alguns dos principais tipos de métricas clássicas para calcular a centralidade são a proximidade, o grau, a intermediação e o autovetor.

- **Centralidade de Grau** (*Degree*) calcula a importância de um nó a partir do número de arestas conectadas a ele. Assim, a centralidade de grau de um nó é igual à quantidade de arestas que ele possui. Em grafos orientados, o grau do nó é medido em termos de grau de entrada, que considera apenas o número de arestas incidentes no nó, ou grau de saída, que considera apenas o número de arestas partindo do nó. O grau relaciona-se com a popularidade do nó, ou quão bem conectado o nó é. Representa-se a centralidade de grau de um nó v_i por

$$C_{deg}(v_i) = deg(v_i). \quad (4)$$

- **Centralidade de Proximidade** (*Closeness*) relaciona-se à rapidez com que um nó alcança todos os outros nós da rede. O cálculo da centralidade de proximidade ($C_C(v_i)$) de cada nó v_i leva em consideração os caminhos mais curtos entre o v_i e todos os outros nós da rede. Matematicamente, a proximidade é dada por

$$C_C(v_i) = \frac{|\mathcal{V}| - 1}{\sum_{j \neq i} \delta^*(v_i, v_j)}, \quad (5)$$

em que $|\mathcal{V}|$ é o número total de nós e $\delta^*(v_i, v_j)$ é a distância mais curta, em número de saltos, entre o par de nós v_i e v_j . Naturalmente, a inexistência de uma conexão entre v_i e v_j implica uma distância $\delta^*(v_i, v_j) = \infty$. A utilização de caminhos mais curtos permite que a complexidade de tempo para computar a proximidade seja $O(|\mathcal{V}| |\mathcal{E}|)$. Na prática, quando usada em um grafo de usuários, a centralidade de proximidade mede efetivamente o quão próximo, em média, cada usuário está de todos os outros usuários em uma comunidade, ou seja, dentro de um grupo de usuários semelhantes que estão densamente conectadas.

- **Centralidade de Intermediação** (*Betweenness*) reflete a fração total de caminhos mais curtos que passam por um nó, usando-o como ponte. Dado um grafo \mathcal{G} , conexo ou não, a centralidade de intermediação (C_B) do nó v_i é definida como

$$C_B(v_i) = \sum_{v_s \neq v_i \neq v_t \in \mathcal{V}} \frac{\sigma_{st}(v_i)}{\sigma_{st}}, \quad (6)$$

em que $\sigma_{st}(v_i)$ representa o número de caminhos mais curtos do nó v_s para o nó v_t que passam pelo nó (v_i) e σ_{st} é total de caminhos mais curtos do nó v_s para o nó v_t . Dessa forma, a relação representa a proporção de caminhos mais curtos entre v_s e v_t que passam por v_i . Implicitamente a centralidade de intermediação relaciona-se com o controle de fluxos ou de informação que são propagados pela rede. Quanto mais central é o nó, maior a proporção de caminhos mais curtos que passam por ele e, conseqüentemente, maior é o controle exercido sobre os fluxos que trafegam na rede pelos caminhos mais curtos. Realizando buscas em largura, algoritmos podem computar a centralidade de intermediação com uma complexidade de tempo igual a $O(|\mathcal{V}| + |\mathcal{E}|)$.

- **Centralidade de Autovetor** (*Eigenvector*) mede a popularidade de um nó ao considerar a popularidade dos vizinhos desse nó. Dessa maneira, o nó mais central segundo essa centralidade é aquele conectado a mais vizinhos populares. Considerando um grafo \mathcal{G} com um matriz de adjacências \mathbf{A} , a centralidade de autovetor para o nó v_i é expressa pelo v_i -ésimo elemento do vetor \mathbf{x} definido por $\mathbf{Ax} = \lambda_{max}\mathbf{x}$, em que λ_{max} é o escalar que representa o maior autovalor associado ao autovetor de \mathbf{A} .
- **Centralidade de Informação** (*Information*) é uma variante da centralidade de proximidade. A centralidade de informação também é chamada de centralidade de proximidade do fluxo de corrente. O valor da centralidade de informação de um nó é determinado com base no fluxo de informação presente em todos os possíveis caminhos entre pares de nós. Essa métrica considera todos os caminhos existentes entre os pares de nós no grafo. Computacionalmente, o cálculo da centralidade de informação é custoso para grandes redes, visto que sua complexidade de tempo possui uma relação cúbica com o número de nós $O(|\mathcal{V}|^3)$. Matematicamente é definida por

$$C_I(v_i) = \frac{|\mathcal{V}|}{\sum_{v_j \in \mathcal{V}} \frac{1}{I(v_i, v_j)}}, \quad (7)$$

em que $|\mathcal{V}|$ é o número de nós no grafo, $\delta^*(v_i, v_j)$ é o custo do caminho mais curto entre v_i e v_j , e $I(v_i, v_j) = \sum_n I_n(v_i, v_j)$ é o somatório da informação medida em todos os caminhos entre v_i e v_j . A informação em um único caminho n é dada por $I_n(v_i, v_j) = 1/\delta_n(v_i, v_j)$, em que $\delta_n(v_i, v_j)$ é o tamanho do caminho n .

- **Centralidade de Katz** indica a influência relativa de um nó dentro de uma rede medindo o número de vizinhos imediatos e de todos os outros nós da rede que se conectam ao nó em questão por meio desses vizinhos imediatos. Sendo uma generalização da centralidade de autovalor, a centralidade de Katz penaliza as conexões com vizinhos distantes através de um fator de atenuação α , tal que $\alpha < 1/\lambda_{max}$. Matematicamente, a centralidade de Katz de um nó v_i é denotada por

$$C_{Katz}(v_i) = \alpha \sum_{v_j \in \mathcal{V}} a_{j,i} C_{Katz}(v_j) + \beta, \quad (8)$$

em que $a_{j,i}$ é um elemento da matriz de adjacências \mathbf{A} de um grafo cujos autovalores são λ , e o parâmetro β representa um peso relacionado aos vizinhos imediatos. O cálculo dessa centralidade tem a mesma complexidade computacional da centralidade de informação.

- **PageRank** é uma variante da centralidade de autovetor e foi originalmente criada para ranquear a importância de uma página *web*. *PageRank* contabiliza a quantidade e a qualidade de *links* referindo-se à página [Page et al., 1999] para definir a importância de uma página. A principal medida para estimar a importância do nó é o grau de entrada. Essa métrica é frequentemente incorporada na análise de grafos, uma vez que pode ser utilizada para medir a popularidade de um nó na rede. Diferentemente da centralidade de Katz, nós com elevado *PageRank* não têm influência

tão significativa na importância dos seus vizinhos. De maneira simplificada, pode-se calcular o valor de *PageRank* de um nó v_i como

$$C_{PageRank}(v_i) = \alpha \sum_{v_j \in \mathcal{V}} \frac{a_{j,i}}{C_{deg}(v_j)} C_{PageRank}(v_j) + \beta, \quad (9)$$

em que $a_{j,i}$ é um elemento da matriz de adjacências \mathbf{A} , α é um fator de amortecimento constante, β é um fator de personalização constante e $C_{deg}(v_j)$ é o grau de saída do nó v_j se esse grau for positivo, ou $C_{deg}(v) = 1$ se o grau de saída for nulo. A Equação 9 é definida de forma recursiva, visto que a análise do *PageRank* de determinado nó depende do *PageRank* de todos os nós vizinhos. Destaca-se que a vizinhança entre dois nós exerce maior relevância no cálculo do *PageRank* se o nó de origem possuir maior *PageRank*. Contudo, o *PageRank* de um nó é impactado negativamente proporcionalmente ao número de arestas partindo de si. O *PageRank* mais alto pode ser interpretado como proporcional à probabilidade de o nó espalhar uma informação em sua comunidade.

Visando capturar a qualidade de uma comunidade localmente, a métrica de **condutância** remete à porcentagem de arestas que atravessam os limites de uma comunidade. Comunidades bem definidas tendem a ter uma pequena condutância, significando a densa presença de arestas internas à comunidade, enquanto que arestas externas são esparsas. Assim, dado um grafo \mathcal{G} não direcionado e sua matriz de adjacências \mathbf{A} , a condutância ϕ de uma comunidade $\mathcal{C} \subset \mathcal{V}$ pode ser calculada pela razão expressa por

$$\phi(\mathcal{C}) = \frac{\sum_{v_i \in \mathcal{C}, v_j \notin \mathcal{C}} a_{i,j}}{\min \{a(\mathcal{C}), a(\overline{\mathcal{C}})\}}, \quad (10)$$

em que o numerador representa o número de arestas intercomunitárias e o denominador representa o número total de arestas da comunidade. Os valores $a(\mathcal{C})$ são dados por $\sum_{v_i \in \mathcal{C}} \sum_{v_j \in \mathcal{V}} a_{i,j}$ e $a(\overline{\mathcal{C}})$ por $\sum_{v_i \notin \mathcal{C}} \sum_{v_j \in \mathcal{V}} a_{i,j}$. A condutância do grafo é dada pela condutância mínima de todas as possíveis comunidades \mathcal{C} , dada por

$$\phi(\mathcal{G}) = \min_{\mathcal{C} \subseteq \mathcal{V}} \phi(\mathcal{C}). \quad (11)$$

A pureza é uma métrica definida pelo produto das frequências dos rótulos mais frequentes associados aos nós de uma comunidade. Cada nó possui um ou mais rótulos que indicam a quais comunidades ele pertence. A pureza de uma comunidade \mathcal{C} é formalizada por

$$P(\mathcal{C}) = \prod_{r \in \mathcal{R}} \frac{\max(\sum_{v_i \in \mathcal{C}} r(v_i))}{|\mathcal{C}|}, \quad (12)$$

em que \mathcal{R} é o conjunto de rótulos, $r \in \mathcal{R}$ é um rótulo e $r(v_i)$ é uma função indicadora que assume valor 1 se $r \in \mathcal{R}(v_i)$.

A partir dos valores de condutância e pureza, Morini *et al.* defendem que o risco de uma comunidade ser efetivamente uma câmara de eco pode ser medido através de

uma comparação com dois limiares, p_0 e φ_0 , arbitrariamente escolhidos de acordo com o rigor da definição de câmara de eco. Supondo uma escolha adequada dos limiares e o cumprimento das condições $P(\mathcal{C}) > p_0$ e $\phi(\mathcal{C}) < \varphi_0$, pode-se que garantir que: i) a maioria dos usuários da comunidade compartilhe o mesmo rótulo ideológico; ii) a maioria das arestas está dentro dos limites da comunidade. Tais características são frequentemente associadas às câmaras de eco [Morini et al., 2021].

1.6.2. Métricas de Controvérsia em Comunidades

A interpretação de comunidades como câmaras de eco tem como vantagem permitir a aplicação das métricas usadas para análise e detecção de comunidades já existentes. Além disso, essa interpretação possibilita obter indícios da presença das câmaras de eco por meio de duas propriedades: a controvérsia e a homogeneidade. Ambas as propriedades quantificam, de forma complementar, a polarização de um tópico debatido entre usuários de uma rede social. Na prática, a **propriedade de controvérsia** pode ser computada utilizando diversas métricas, tais como *Random Walk Controversy* (RWC), *Authoritative Random Walk Controversy* (ARWC), *Displacement Random Walk Controversy* (DRWC) e *Boundary Connectivity* (BC).

A métrica *Random Walk Controversy* (RWC), originalmente proposta por Garimella *et al.*, considera duas comunidades \mathcal{X} e \mathcal{Y} do grafo \mathcal{G} , tal que $\mathcal{X} \cup \mathcal{Y} = \mathcal{V}$, e $\mathcal{X} \cap \mathcal{Y} = \emptyset$. Além disso, são considerados dois passeios aleatórios, um terminando na comunidade \mathcal{X} e o outro terminando na comunidade \mathcal{Y} [Garimella et al., 2018b]. Definida no intervalo $[0, 1]$, a RWC expressa a diferença das probabilidades de dois eventos, um considerando que ambos os passeios aleatórios começam e terminam na mesma comunidade, e outro assumindo que ambos os passeios aleatórios começam de uma comunidade e terminam na outra. Matematicamente, essa diferença é computada por

$$RWC = P_{\mathcal{X} \rightarrow \mathcal{X}} P_{\mathcal{Y} \rightarrow \mathcal{Y}} - P_{\mathcal{X} \rightarrow \mathcal{Y}} P_{\mathcal{Y} \rightarrow \mathcal{X}}, \quad (13)$$

em que $P_{\mathcal{A} \rightarrow \mathcal{B}}$ representa a probabilidade condicional de um passeio aleatório começar na comunidade \mathcal{A} e terminar na \mathcal{B} , tal que $\mathcal{A}, \mathcal{B} \in \{\mathcal{X}, \mathcal{Y}\}$. Diante disso, espera-se que quanto mais próximo do valor mínimo, maior a probabilidade de migração para a outra comunidade e menor a controvérsia do grafo. Por outro lado, quanto mais próximo do valor máximo, maior a probabilidade de permanência na comunidade original e consequentemente é indicativo da presença de controvérsia.

A métrica ARWC [Villa et al., 2021], proposta por Villa *et al.*, é derivada da RWC, mas distingue-se dela pelo fato de não adotar uma seleção completamente aleatória dos nós iniciais utilizados no passeio aleatório. A ARWC parte apenas dos intitulados nós autoritativos. Tal classificação é atribuída a um conjunto de nós específicos do grafo, com base na centralidade de grau dos mesmos. Essa alteração do ponto de partida permite capturar a probabilidade de um usuário casual, pertencente a uma determinada comunidade, ser exposto ao conteúdo disseminado por um nó autoritativo da comunidade oposta. No cálculo da ARWC, o passeio aleatório termina quando um nó pertencente ao conjunto de nós autoritativos de uma ou outra partição é alcançado.

Igualmente proposta por Villa *et al.*, a métrica DRWC reflete a razão entre o número de passos, durante um passeio aleatório de comprimento fixo, que resulta em uma mudança de comunidade e o comprimento total do passeio [Villa et al., 2021]. Sendo

definida entre $[0, 1]$, a métrica é formalmente expressa por

$$DRWC = \frac{\sum_{\forall v_i \in \mathcal{N}} \left[1 - \left(\frac{n(v_i)_{cc}}{l_{rw}} \right) \right]}{|\mathcal{N}|}, \quad (14)$$

em que \mathcal{N} representa o conjunto de vértices aleatoriamente selecionados; l_{rw} ¹⁰ é o comprimento do passeio aleatório contabilizado em número de arestas; e $n(v_i)_{cc}$ ¹¹ consiste no número de passos no passeio aleatório do nó v_i , onde o nó migrou de comunidade. Vale ressaltar que, caso nenhuma mudança de comunidade seja identificada durante todo o passeio aleatório de um nó, pode-se inferir que há controvérsia entre as duas comunidades. Não obstante, caso a alternância de comunidade seja frequente, há evidências de que as comunidades apresentam um baixo grau de controvérsia entre si.

Por fim, a métrica BC [Guerra et al., 2013] baseia-se nos conceitos de nós internos e nós limítrofes para mensurar a controvérsia entre duas comunidades. Para pertencer ao conjunto de nós limítrofes $\mathcal{B}_{\mathcal{X}}$ de uma comunidade \mathcal{X} , um nó do grafo precisa satisfazer duas condições simultaneamente: i) possuir pelo menos uma aresta conectada a um nó da comunidade oposta \mathcal{Y} ; ii) possuir pelo menos uma aresta conectada a um membro de \mathcal{X} que não está conectado a \mathcal{Y} . Paralelamente, o conjunto de nós da comunidade \mathcal{X} que não pertencem à $\mathcal{B}_{\mathcal{X}}$, são denominados nós internos $\mathcal{I}_{\mathcal{X}}$. Vale ressaltar que, se as duas comunidades constituem câmaras de eco, os nós limítrofes de cada comunidade seriam mais fortemente conectados com os nós internos da mesma comunidade do que com os nós limítrofes da comunidade oposta. A formalização matemática da métrica BC é dada por

$$BC = \frac{1}{|\mathcal{B}|} \sum_{v_s \in \mathcal{B}} \left[\frac{C_{deg}^i(v_s)}{C_{deg}^b(v_s) + C_{deg}^i(v_s)} - 0,5 \right], \quad (15)$$

em que $C_{deg}^i(v_s)$ representa o número de arestas entre o nó v_s e os elementos do conjunto \mathcal{I} ; e $C_{deg}^b(v_s)$ é o número de arestas entre o nó v_s e os elementos do conjunto \mathcal{B} . Diferentemente das métricas de controvérsia acima descritas, BC é definida entre $[-0.5, 0.5]$, em que valores maiores que zero expressam uma provável presença de controvérsia, enquanto que valores menores que zero indicam falta de polarização. Nesse contexto, quanto maiores os níveis de controvérsia entre nós de diferentes comunidades e de homogeneidade entre nós de uma mesma comunidade, maior a probabilidade da existência de câmaras de eco no grafo analisado [Villa et al., 2021].

1.6.3. Modelagem de Câmaras de Eco e Bolhas de Filtro

Devido à dificuldade de obtenção de bases de dados reais sobre câmaras de eco, alguns trabalhos empregam modelos estatísticos para investigar as câmaras de eco e a propagação de informações e opiniões dentro delas. Embora detenham critérios de propagação particulares, os modelos abaixo podem ser agrupados segundo a forma de representação [Alatawi et al., 2021].

A **Dinâmica Friedkin-Johnson (FJ)** é um modelo de propagação de opinião segundo uma perspectiva de tempo discreto $t \in [0, 1, \dots, T]$. O modelo trata a opinião atual

¹⁰*rw*: random walk.

¹¹*cc*: change community.

de um usuário como uma composição entre uma parcela estática, inerente à própria opinião inata e outra parcela variável no tempo, que é atualizada mediante a influência social. Independentemente do grau de generalização do assunto, específico ou genérico, a dinâmica FJ assume que as opiniões variáveis no tempo podem ser codificadas por um valor real contínuo dentro do espectro polar de $[-1, 1]$. Assim, a completa discordância ou concordância a respeito de um determinado assunto é representada pelos valores extremos do intervalo, respectivamente, enquanto que um valor nulo representa uma opinião nula. Sendo o diferencial do modelo, a intitulada opinião inata é a parcela blindada da influência externa de outros usuários e imutável temporalmente. A construção dessa opinião interna é um resultado histórico, localização geográfica, religião, raça ou outras circunstâncias intrínsecas ao indivíduo. Essa estratégia de modelagem é particularmente útil no estudo de câmaras de eco e bolhas de filtro, quando deseja-se simular a inclinação de diferentes usuários em uma rede social [Chitra e Musco, 2020].

O **Modelo de Bloco Estocástico (SBM)** cria um modelo de grafo de uma comunidade em que os parâmetros do modelo definem o quanto os membros de uma comunidade se misturam dentro e fora de sua comunidade. Assim, o SBM cria um grafo aleatório com base em vários parâmetros. A suposição básica é que existem duas ou mais comunidades criadas a partir de n nós. O SBM é especialmente útil quando combinado com a suposição de homofilia, ou seja, pessoas com inclinações semelhantes tendem a estar conectadas. Deve-se notar, no entanto, que esse modelo não simula homofilia por padrão. O grafo aleatório parametrizado é criado de forma que para cada par de nós, há uma probabilidade p de estarem conectados, dado que estão na mesma comunidade, e há uma probabilidade q de estarem conectados se estiverem em comunidades diferentes. O resultado é um grafo sobre ambas as comunidades. Para simular a homofilia, define-se p maior que q , resultando em nós com as mesmas inclinações, isto é, pertencentes às mesmas comunidades, sendo mais conectados dentro dessas comunidades. O SBM pode ser útil quando combinado com o modelo FJ para estudar os efeitos de bolhas de filtro [Chitra e Musco, 2020]. O modelo FJ é útil para determinar as tendências de equilíbrio dos indivíduos enquanto o SBM pode fornecer uma maneira de modelar o estado inicial da rede social. Pode-se simular bolhas de filtro adicionando ou removendo arestas [Gausen et al., 2022].

Considerando a hipótese de que no interior das câmaras de eco há prevalência pela divulgação de conteúdos de carácter duvidoso ou falso, pode-se utilizar o modelo de propagação baseado em **Cascata** [Minici et al., 2022]. Nesse modelo, uma estrutura em árvore representa todo o processo de disseminação do conteúdo, podendo ser pautada tanto em uma perspectiva por saltos quanto por tempo. Nessa estrutura, o nó-raiz retrata o primeiro usuário a publicar ou criar um conteúdo e os demais nós representam usuários atuantes no encaminhamento ou compartilhamento do conteúdo falso. A semelhança em cascata entre vários discursos desconexos pode ajudar na detecção da câmara de eco [Tokita et al., 2021].

O modelo de **Confiança Limitada** proposto por Deffuant *et al.* é empregado na predição das opiniões dos usuários com base em suas interações [Deffuant et al., 2000]. Ao representar a opinião de um usuário por um valor dentro do intervalo assimétrico $[0, 1]$, o modelo assume que qualquer mudança de opinião está relacionada ao parâmetro de confiança limitado γ . Interpretado como um grau de abertura a novas opiniões, o parâmetro γ define o limite na distância entre a opinião dos dois usuários além do qual a

comunicação entre eles não é possível devido a visões conflitantes. Limiares altos geram convergência de opiniões para uma opinião média, ao passo que limiares baixos resultam em vários agrupamentos de opinião, formando, por exemplo, as câmaras de eco. Dessa forma, membros de uma mesma comunidade compartilham a mesma opinião, mas não se ajustam mais com membros de outras comunidades [Sîrbu et al., 2019].

1.7. Representação Vetorial de Textos

Ao optar pela detecção de câmaras de eco segundo a abordagem ideológica, os textos tornam-se a principal matéria-prima de análise. Contudo, para facilitar qualquer análise semântica sobre os conjuntos de dados textuais coletados é essencial que estes sejam primeiramente transformados em estruturas matematicamente operáveis, como matrizes ou vetores numéricos. Essa transformação pode ser desempenhada pelo **Modelo de Espaço Vetorial**, o qual define que textos podem ser interpretados como um espaço vetorial de palavras, em que cada palavra pode ser representada em diferentes padrões. Tais padrões de representação podem embasar-se na: i) contagem binária, em que para cada palavra é atribuído 1 ou 0 de acordo com presença ou ausência da palavra na sentença; ii) contagem cumulativa, usando o Saco-de-Palavras (*Bag-of-Words*), um modelo que computa o número de citações de determinada palavra na sentença; e iii) frequência, usando *tf-idf* (Frequência do Termo–Inverso da Frequência), uma medida estatística que indica a importância de uma palavra de uma sentença em relação a uma coleção de sentenças, ou seja, a base de dados [de Oliveira et al., 2020b]. Apesar da simplicidade e robustez, os modelos clássicos de vetorização tratam as palavras como unidades atômicas, isto é, sem uma conexão semântica entre si. Embora este fator seja menos danoso em uma avaliação da similaridade entre frases ou documentos, esses modelos são incapazes de lidar com a avaliação semântica das palavras. Esse empobrecimento semântico torna palavras com sentidos próximos ou sinônimos totalmente invisíveis à modelagem vetorial. Outra desvantagem consiste na alta dimensionalidade, um reflexo do caráter esparso dos vetores gerados [de Oliveira et al., 2020b, Mikolov et al., 2013].

As dificuldades encontradas em relação às técnicas clássicas de vetorização motivaram o desenvolvimento de técnicas de **incorporações de palavras** (*words embeddings*), uma forma de representação distribuída de palavras. Intimamente ligada a essa forma de representação, a hipótese distribucional manifesta que cada palavra é caracterizada pela sua vizinhança, expressando portanto, uma tendência de palavras com significados semelhantes ocorrerem em contextos similares. Tais representações de palavras podem ser obtidas aplicando modelos preditivos baseados em redes neurais que, quando treinados com grandes volumes de dados textuais, incorporam a semântica das palavras em vetores de baixa dimensão, densos e de tamanho fixo. O principal benefício dessa representação vetorial individualizada para cada palavra encontra-se na preservação das relações semânticas e sintáticas entre palavras. Essa habilidade garante que sinônimos ou palavras minimamente relacionadas sejam mapeados em vetores similares. A ferramenta *Word2Vec* auxiliou na popularização das técnicas de incorporações de palavras [Mikolov et al., 2013]. Essa ferramenta calcula a representação vetorial de palavras por meio de dois modelos possíveis, o Saco de Palavras Contínuo (*Continuous Bag-of-Words - CBOW*) e o *Skip-gram*, que operam dividindo os textos em dois grupos, palavra-alvo e contexto. O contexto é interpretado como um conjunto limitado das palavras localizado

ao redor da palavra-alvo. O tamanho dessa limitação é determinado por uma janela que define o número de palavras a serem consideradas imediatamente à esquerda e à direita da palavra-alvo. O modelo CBOW converge de maneira mais rápida em relação ao *Skip-gram*. Contudo, em relação ao CBOW, o *Skip-gram* apresenta melhores resultados para palavras pouco frequentes. A particularidade do modelo *Skip-gram* está na sua capacidade de usar uma palavra-alvo w_t na predição do contexto de palavras $[w_{t-j}, \dots, w_{t+j}]$ em um conjunto de palavras que circunda a palavra-alvo. Já o modelo CBOW inverte a atuação da palavra-alvo e das palavras de contexto, de forma que possibilita a predição de uma palavra-alvo a partir do contexto de palavras próximas.

A Figura 1.4 mostra a arquitetura do modelo *Skip-gram*. A arquitetura é composta pelas camadas de entrada e de saída, intercaladas por uma camada oculta. O número de palavras V existentes no vocabulário usado no treinamento determina o tamanho das camadas de entrada e de saída. Já o tamanho da camada oculta é determinado com base em um parâmetro N arbitrário, que expressa a dimensão do futuro vetor de palavras gerado H (*word embeddings*). Essa dimensão indica a quantidade de características usadas na representação numérica de cada palavra, sendo, portanto, inferior à dimensão do vetor original de cada palavra inserido na camada de entrada. A conexão da camada de entrada para a camada oculta é feita através de uma matriz de pesos W_I de tamanho $V \times N$. Analogamente, a conexão da camada oculta para a camada de saída é desempenhada pela matriz W_O de tamanho $N \times V$. Ambas as matrizes de peso W_I e W_O são inicializadas com valores aleatórios pequenos. A inserção de uma palavra-alvo na camada de entrada da rede neural inicia com a codificação dessa palavra em seu vetor *one-hot*, uma matriz coluna $V \times 1$ usada para distinguir cada palavra em um vocabulário. Esse vetor consiste em 0s em todas as posições, com exceção de um único 1 na posição x_i usada exclusivamente para identificar a palavra [de Oliveira et al., 2021b].

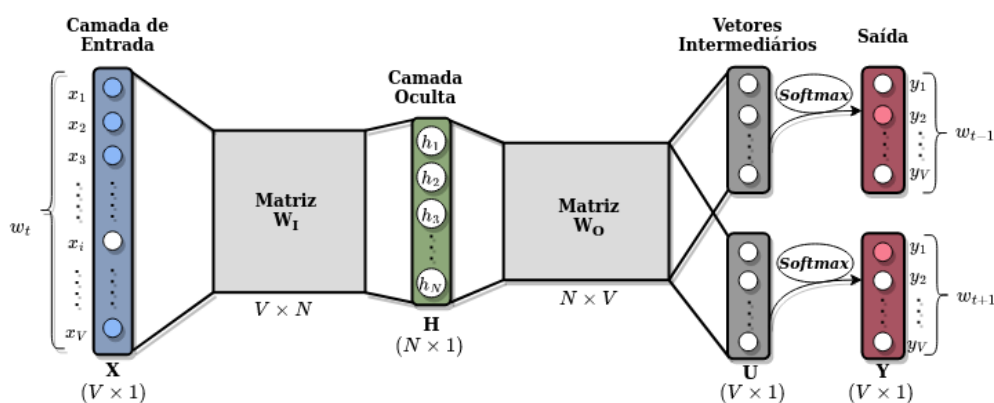


Figura 1.4. Arquitetura do modelo *Skip-gram* considerando como entrada a palavra-alvo w_t codificada no seu vetor *one-hot* X . Na saída do modelo são obtidos C vetores de distribuição de probabilidade, um para cada palavra do contexto. Com o modelo devidamente treinado, espera-se que as maiores probabilidades de cada vetor Y , encontradas nas posições y_2 e y_1 , expressem as palavras de contexto w_{t-1} e w_{t+1} relacionadas a palavra alvo. Adaptado de [de Oliveira et al., 2021b].

No processo de treinamento, a cada iteração são empregados dois algoritmos de aprendizado: de propagação direta (*forward propagation*) e de retropropagação (*back-*

propagation). Aplicando primeiramente o algoritmo de propagação direta, o vetor *one-hot* da palavra-alvo de entrada é multiplicado pela matriz de pesos W_I para formar o vetor H da camada oculta. Em seguida, o vetor H é então multiplicado por W_O gerando assim C vetores intermediários idênticos, cada um representando uma palavra de contexto. As saídas do modelo são adquiridas aplicando a cada vetor intermediário a função *softmax*. Esta função tem o objetivo de normalizar o vetor intermediário U composto por V números flutuantes, transformando-o no vetor de distribuição de probabilidade Y . Uma vez descoberto o vetor normalizado de probabilidades de cada palavra de contexto, o algoritmo de retropropagação os compara com o vetor *one-hot* da palavra correspondente para assim atualizar as matrizes de peso W_I e W_O . Essa atualização ocorre especificamente nos valores da coluna correspondente de W_O e da linha correspondente de W_I . No modelo CBOW, devido à inversão da atuação da palavra-alvo e das palavras de contexto, admitem-se múltiplas entradas, uma para cada palavra de contexto. Devido à multiplicidade de vetores de entrada é necessário calcular a média dos vetores de palavras correspondentes, construídos pela multiplicação dos múltiplos vetores *one-hot* de entrada e pela matriz W . Uma segunda consequência da inversão é a presença de uma única função *softmax*, ao contrário das C existentes na arquitetura do modelo *Skip-gram*.

1.8. Representação Vetorial de Grafos

A adoção da abordagem topológica para a identificação de câmaras de eco implica a necessidade de modelar a rede como um grafo. A transformação de um grafo em uma representação vetorial auxilia na avaliação quantitativa da qualidade da estrutura da comunidade gerada. Na representação vetorial de grafos, os nós do grafo são mapeados em um espaço vetorial derivado. Goyal e Ferrara argumentam que a obtenção de representação vetorial de grafos é uma tarefa inerentemente desafiadora e precisa atender-se a três aspectos [Goyal e Ferrara, 2018]:

- **Preservação de Propriedades.** A qualidade de uma representação vetorial de grafos está atrelada à sua capacidade de preservar as propriedades estruturais da conexão entre os nós individuais. Esse grau de preservação pode ser delimitado segundo três tipos de medidas de proximidade. A *proximidade de primeira ordem* visa quantificar a similaridade local entre os nós a partir do peso da aresta que os interliga. A *proximidade de segunda ordem* captura a proximidade entre as estruturas de vizinhança dos nós. Tal proximidade pode ser facilmente estimada usando a métrica de probabilidade de transição entre dois nós. Embora exista a *proximidade de alta ordem*, essa tem pouca ocorrência na literatura uma vez que a proximidade de segunda ordem supre satisfatoriamente a necessidade da maioria dos métodos de incorporação de grafos.
- **Escalabilidade.** Caracterizadas pela grande quantidade de nós e arestas, as redes sociais têm seu processamento e análise diretamente impactados pelo modelo de representação vetorial adotado. A aplicação de métodos tradicionais nessas redes gera representações vetoriais demasiadamente extensas, com dimensão proporcional ao número de nós. Esse aspecto compromete a aplicabilidade de métodos de representações vetoriais às redes reais de grande escala. Na prática, a definição de métodos de vetorização escaláveis é especialmente difícil quando se deseja preser-




Figura 1.5. Diferentes tipos de grafos e suas respectivas representações matriciais de adjacência. A primeira linha de (A) a (C) são, respectivamente, exemplos de grafos direcionados, não direcionados e ponderados. A principal diferença entre (A) e (B) é que as arestas são direcionadas em (A), mas não direcionadas em (B). (C) mostra um grafo ponderado onde cada aresta é ponderada com um valor específico. As matrizes de adjacência 4×4 correspondentes a cada grafo encontram-se imediatamente abaixo dos mesmos. Convém ressaltar que como nenhum grafo possui auto-laços (*self-loops*), *i.e.*, arestas que se originam e terminam no mesmo nó, as matrizes de adjacência de cada grafo têm todos os elementos da diagonal principal nulos.

var as propriedades globais da rede.

- **Dimensionalidade.** O dimensionamento ótimo de representações vetoriais de grafos é uma tarefa subjetiva. Embora a escolha de um número maior de dimensões possa favorecer precisão em tarefas de reconstrução do grafos, isso também pode aumentar a complexidade computacional de procedimentos ou algoritmos subsequentes.

1.8.1. Matriz de Adjacências

A matriz de adjacências apresenta-se como uma das estratégias mais simples e tradicionais de vetorização de grafos. A matriz de adjacência permite representar um grafo \mathcal{G} composto por $|\mathcal{V}|$ vértices por meio de uma matriz $\mathbf{A}(\mathcal{G}) = [a_{ij}]$ de dimensão $n \times n$, em que os elementos a_{ij} da matriz dependem das propriedades intrínsecas ao grafo. Supondo um grafo não ponderado, seja direcionado ou não direcionado, cada elemento a_{ij} da matriz \mathbf{A} contém 1, caso v_i e v_j sejam adjacentes e 0 caso contrário. Em grafos ponderados, os elementos a_{ij} retratam o peso da aresta entre v_i e v_j . Essa lógica de preenchimento garante que grafos não direcionados sejam mapeados em matrizes de adjacência simétricas ao longo da diagonal principal. Todavia, tal simetria não é garantida em grafos direcionados. Embora o vetor de adjacências de um nó codifique a estrutura de vizinhança de primeira ordem de um nó, o vetor resultante é esparsa, discreto e de alta dimensionalidade devido à natureza esparsa de redes de grande escala [Cui et al., 2019, Xu, 2021].




Figura 1.6. Visão genérica do processo de incorporação de grafos. Partindo de um grafo previamente estruturado, este pode ser submetido a três tipos de métodos de incorporação, sendo eles: (A) baseados em fatoração de matrizes, que aplicam técnicas de redução dimensional em representações matriciais do grafo original; (B) baseados em passeio aleatório, que geram sequências aleatórias de nós para nutrir modelos de incorporação e.g., *Word2vec*; e (C) baseados em aprendizado profundo, que utilizam rede neurais com arquiteturas e entradas específicas. Após obter uma representação vetorial densa e de baixa dimensão sobre nó do grafo, pode-se construir classificadores específicos para diferentes aplicações. Adaptado de [Yue et al., 2020].

1.8.2. Incorporação de Grafos

Na literatura, o termo *incorporação de grafos* é descrito como uma forma de representar um grafo inteiro, ou cada nó individualmente, em um espaço vetorial de menor dimensão que o original. Assim, o principal objetivo da incorporação de grafos baseados em pontos vetoriais consiste em projetar nós de grafos de alta dimensão em vetores de baixa dimensão em um espaço latente. Nessa transformação deve-se garantir a preservação das propriedades originais da estrutura do grafo, de forma que nós próximos entre si no grafo original sejam posteriormente incorporados a um espaço latente com representações vetoriais semelhantes [Xu, 2021]. Os métodos de incorporação de grafos podem ser categorizados em três tipos principais baseados em i) fatoração de matrizes; ii) passeio aleatório; e iii) aprendizado profundo. A Tabela 1.4 sumariza as características de alguns métodos pertencentes a cada tipo. A complexidade de diversos algoritmos mostrados na tabela é dependente da dimensão d escolhida para a incorporação. Esta seção discute os métodos e algoritmos enumerados na tabela.

Incorporação Baseada na Fatoração de Matrizes

Os métodos de incorporação de grafos baseados em fatoração representam as conexões entre nós na forma de uma matriz e fatorizam essa matriz para obter a incorporação. Dentre os tipos de matrizes utilizáveis para representar as conexões estão a matriz de adjacências de nós, matriz Laplaciana, matriz de probabilidade de transição de nós e matriz de similaridade de Katz. Dependendo das propriedades originais da matriz, adota-se uma abordagem de fatoração específica. Nesse contexto, matrizes positivas semidefini-

Tabela 1.4. Principais Métodos e Algoritmos de Incorporação de Grafos.

Categoria	Referência	Método ou Algoritmo	Complexidade de Tempo	Propriedades Preservadas
Fatoração	[Roweis e Saul, 2000]	LLE	$O(\mathcal{E} d^2)$	Proximidade de 1 ^a ordem
	[Belkin e Niyogi, 2001]	Automapas Laplacianos	$O(\mathcal{E} d^2)$	
	[Ahmed et al., 2013]	Fatoração de Grafo	$O(\mathcal{E} d)$	
	[Cao et al., 2015]	GraRep	$O(\mathcal{V} ^3)$	Proximidades de 1-k ^a ordem
	[Ou et al., 2016]	HOPE	$O(\mathcal{E} d^2)$	
Passeio Aleatório	[Perozzi et al., 2014]	DeepWalk	$O(\mathcal{V} d)$	Proximidade de 1-k ^a , equivalência estrutural
	[Grover e Leskovec, 2016]	Node2vec	$O(\mathcal{V} d)$	
Aprendizado Profundo	[Cao et al., 2016]	DNGR	$O(\mathcal{V} ^2)$	Proximidades de 1-k ^a ordem
	[Welling e Kipf, 2016]	GCN	$O(\mathcal{E} d^2)$	
	[Wang et al., 2016]	SDNE	$O(\mathcal{V} \mathcal{E})$	Proximidades de 1 ^a e 2 ^a ordem
Miscelânea	[Tang et al., 2015]	LINE	$O(\mathcal{E} d)$	

das, e.g., a matriz Laplaciana, podem ser submetidas à decomposição de autovalores, ao passo que matrizes não estruturadas podem ser incorporadas segundo métodos de gradiente descendente [Goyal e Ferrara, 2018]. Outra técnica comumente utilizada na fatoração de matrizes é a Decomposição de Valor Singular (SVD). A partir da seleção de um nível de aproximação k , a SVD encontra uma versão aproximada da estrutura matricial do grafo original, omitindo todos, exceto os k maiores valores singulares na decomposição.

O algoritmo **Automapas Laplacianos** [Belkin e Niyogi, 2001] parte da premissa que nós interligados por arestas fortemente ponderadas devem possuir incorporações semelhantes. Para atingir esse objetivo, o algoritmo inicia construindo um grafo seguindo um abordagem baseada na ε -vizinhança ou uma abordagem baseada em K -vizinhos mais próximos. Embora seja geometricamente motivada, a primeira abordagem pode frequentemente gerar muitas componentes conectadas dependendo do valor do parâmetro ε . Tal parâmetro reflete o limiar máximo da distância entre dois nós para ambos que sejam interligados por uma aresta. Independentemente da escolha da abordagem de construção, o algoritmo posteriormente atribui pesos às arestas utilizando ponderação unitária ou calculando-os através da função *heat kernel*¹². Por fim, o algoritmo computa os automapas gerando as representações em baixa dimensão de cada nó. O caráter de preservação de localidade do algoritmo, torna-o relativamente insensível a pontos discrepantes (*outliers*) e ruídos. Um subproduto dessa preservação é que o algoritmo enfatiza implicitamente as

¹²Função dada por $h_t = e^{-\frac{\|v_i - v_j\|^2}{t}}$, em que t é o tempo e v_i e v_j são os nós conectados por uma aresta.

comunidades naturais nos dados.

A **Fatoração de Grafos** (GF) [Ahmed et al., 2013] é um método que propõe uma incorporação de grafos por meio da fatoração da matriz de adjacências do grafo de entrada. Esse método aplica uma técnica de fatoração baseada em particionamento do grafo, visando minimizar o número de nós vizinhos em vez de arestas entre as partições. Internamente, a função objetivo do método contém um coeficiente de regulação intuitivamente ajustável e capaz de controlar a generalização da incorporação gerada. Um coeficiente de regularização baixo propicia uma melhor reconstrução, porém pode eventualmente particularizar, levando a um desempenho de previsão ruim. Por outro lado, a escolha de um coeficiente demasiadamente alto põe em uma vez que resulta numa sub-representação os dados [Goyal e Ferrara, 2018].

Proposto por Ou *et al.*, o método **HOPE** (*High-Order Proximity preserved Embedding*) visa preservar a propriedade de transitividade assimétrica, uma propriedade crítica em redes direcionadas [Ou et al., 2016]. A transitividade assimétrica retrata a correlação entre arestas, indicando que se houver um caminho direcionado de v_i para v_j , então provavelmente há uma aresta direcionada de v_i para v_j . Para preservar esta propriedade, o HOPE constrói uma formulação geral de quatro medidas de proximidade de alta ordem. Posteriormente, aplica-se o SVD generalizado à formulação a fim de encontrar uma versão aproximada e compacta. Esse processo de redução dimensional diminui significativamente a complexidade de tempo do método [Cui et al., 2019]. O HOPE fornece um limite superior teórico para o erro de aproximação e, assim, consegue estimar a qualidade da incorporação e determinar as dimensões de incorporação automaticamente.

Incorporação Baseada em Passeio Aleatório

A tentativa de transpor a tarefa de incorporação de um cenário linguístico para um cenário em grafos, depara-se com a indeterminação de como delimitar adequadamente a vizinhança em grafos. Para contornar essa indeterminação, alguns métodos de incorporação de grafos baseiam-se no conceito de passeio aleatório para amostrar aleatoriamente os vizinhos do nó e assim extrair o contexto estrutural do nó. A aplicabilidade do passeio aleatório na incorporação de grafos torna-se mais evidente quando o grafo está parcialmente disponível ou é demasiadamente grande para ser analisado em sua totalidade [Goyal e Ferrara, 2018]. Estabelecendo um paralelo com o cenário textual, cada nó integrante de um grafo é tratado como uma palavra individual, enquanto que um passeio aleatório é interpretado como uma sentença [Cui et al., 2019]. Além do processo de amostragem com passeio aleatório, os métodos de incorporação baseados em passeio aleatório costumam incluir um modelo de incorporação tipicamente usados para linguagem, como o *SkipGram*. Tais modelos atuam como codificadores eficazes para problemas prevalentes de incorporação de nós de grafos. Dessa forma, os métodos baseados em passeio aleatório conseguem codificar efetivamente a estrutura e as informações topológicas do grafo original no espaço latente.

O **DeepWalk** [Perozzi et al., 2014] preserva a proximidade de ordem superior entre os nós maximizando a probabilidade de observar os últimos k nós e os próximos k nós no passeio aleatório centrado em v_i , ou seja, maximizando

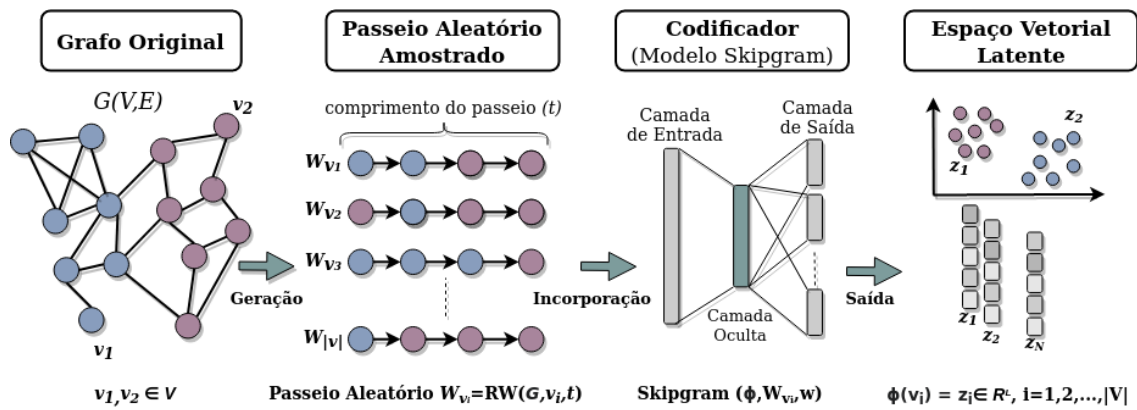


Figura 1.7. Processo de incorporação de grafos implementado por métodos baseados em passeio aleatório. Em posse do grafo de entrada, os métodos inicialmente aplicam um procedimento de amostragem de nós baseada no passeio aleatório. Cada passeio aleatório parte de um nó do grafo e tem um comprimento em saltos fixo igual a t . Assim, cada passeio aleatório pode ser representado pelo contexto do nó correspondente. Em seguida, um modelo de incorporação de linguagem desempenha o papel de um codificador de modo que cada nó seja representado como um vetor contínuo de baixa dimensão no espaço latente. Nesses vetores estão preservadas as propriedades estruturais do grafo original. Adaptado de [Xu, 2021].

$\log P_r(v_{i-k}, \dots, v_{i-1}, v_{i+1}, \dots, v_{i+k} | Y_i)$, onde Y_i é e $2k + 1$ é o comprimento do passeio aleatório. Assim, o modelo gera vários passeios aleatórios cada um com comprimento $2k + 1$ e realiza a otimização sobre a soma das probabilidades logarítmicas para cada passeio aleatório. Um decodificador baseado em produto escalar é usado para reconstruir as arestas das incorporações de nós.

O algoritmo **Node2Vec**¹³ integra o modelo *Skip-gram* em seu funcionamento. O *Node2Vec* permite mapear nós em representações vetoriais densas e de baixa dimensão [Grover e Leskovec, 2016]. Nesse espaço de incorporação, garante-se a preservação da estrutura de comunidade, bem como a equivalência estrutural entre nós do grafo original. Para preservar a proximidade de ordem superior entre nós, o *Node2vec* maximiza a probabilidade de ocorrência de nós subsequentes em passeios aleatórios de comprimento fixo [Cui et al., 2019, Goyal e Ferrara, 2018]. Diferentemente do *DeepWalk*, o *Node2vec* emprega passeios aleatórios tendenciosos que fornecem uma troca entre buscas em largura (*Breadth-First Search* - BFS) e em profundidade (*Depth-First Search* - DFS). A consequência disso é a produção de incorporações de maior qualidade e mais informativas comparadas às do *DeepWalk*.

Incorporação Baseada em Aprendizado Profundo

A incorporação de grafos é inerentemente uma tarefa que transforma o espaço original em um espaço vetorial de baixa dimensão. O desafio intrínseco a essa tarefa está justamente no aprendizado de uma função de mapeamento entre esses dois espaços. Na tentativa de resolver esse desafio, os métodos de incorporação baseados em fatoração de matrizes assumem que a função de mapeamento é linear. No entanto, diante da comple-

¹³Disponível em <https://github.com/aditya-grover/node2vec>.

xidade do processo de formação de um grafo, não há garantias que esse processo seja linearmente modelável. Sendo assim, uma função linear pode não ser suficientemente capaz de mapear o grafo original para um espaço de incorporação. Nesse contexto, as redes neurais profundas apresentam-se como uma solução eficaz para aprender funções não lineares de incorporação de grafos. Os principais desafios são o ajuste de modelos profundos aos dados da rede e a imposição da estrutura da rede e as restrições de nível de propriedade aos modelos profundos [Cui et al., 2019].

Idealizado por Wang *et al.*, o **SDNE** (*Structural Deep Network Embedding*) emprega um modelo profundo semi-supervisionado para preservar as proximidades de primeira e segunda ordem de um grafo [Wang et al., 2016]. O modelo é composto por várias camadas de funções não lineares e pode ser dividido em uma componente não supervisionada e outra supervisionada. Internamente, a componente supervisionada explora a proximidade de segunda ordem para preservar a estrutura global do grafo, reconstruindo a estrutura de vizinhança de cada nó. Enquanto isso, a componente supervisionada explora a proximidade de primeira ordem para preservar a estrutura local do grafo. Essa componente supervisionada é baseada no algoritmo de automapas laplacianos que aplica uma penalidade quando vértices semelhantes são mapeados longes um do outro no espaço de incorporação. Tais características garantem a robustez necessária para que o SDNE lide com redes esparsas.

Indicado para incorporação em redes de larga escala, o **LINE** define explicitamente duas funções [Tang et al., 2015]. A primeira função, destinada à preservação da proximidade de primeira ordem, mede a similaridade entre pares de nós através da distribuição de probabilidade conjunta entre eles. Essa primeira função assemelha-se com aquela adotada no método de Fatoração de Grafos, um vez que ambas visam manter próximos a matriz de adjacências e o produto escalar das incorporações. Paralelamente, a segunda função visa preservar a proximidade de primeira ordem medindo a semelhança dos vizinhos, *i.e.*, o contexto de dois nós. A distribuição condicional implica que nós com distribuições semelhantes nos contextos sejam semelhantes entre si. Ao minimizar a divergência de Kullback-Leibler das duas distribuições e das distribuições empíricas, pode-se obter as representações de nós que são capazes de preservar as proximidades de primeira e segunda ordem [Cui et al., 2019, Goyal e Ferrara, 2018].

1.9. Delimitação e Análise de Câmaras de Eco em Redes Sociais

As câmaras de eco são estruturas que têm o potencial de ampliar as ideias disseminadas dentro da própria estrutura ao mesmo tempo em que isola essas ideias de refutação. Essas estruturas são formadas por usuários altamente conectados. A comunidade em uma rede social também é uma estrutura altamente conectada, formada por um subconjunto de nós da rede que possuem maior densidade de conexões entre eles do que com o restante dos nós da rede. Assim, estruturalmente, as câmaras de eco podem ser interpretadas como comunidades em um grafo, de forma que algoritmos de detecção de comunidade amplamente difundidos na literatura podem ser empregados para identificar e delimitar as câmaras de eco. A qualidade das comunidades encontradas é avaliada por meio de métricas de avaliação extrínsecas e intrínsecas. Esta seção apresenta diversos algoritmos utilizados para detecção de comunidade e métricas de avaliação que podem ser aplicados para delimitação e análise de câmaras de eco em redes sociais.

1.9.1. Algoritmos de Detecção de Comunidade

Os algoritmos de detecção de comunidade são capazes de desvendar a existência de uma organização de rede interna não trivial de modo geral. Isso permite inferir relações especiais entre os nós que podem não ser facilmente acessíveis a partir de testes empíricos diretos e ajuda a entender melhor as propriedades dos processos dinâmicos que ocorrem em uma rede [Yang et al., 2016]. Embora cada algoritmo detenha uma lógica própria, todos convergem para um objetivo comum de encontrar subgrafos com características estruturais homogêneas. Sendo a métrica base de diversos algoritmos, a modularidade reflete a tendência de formar agrupamentos que podem ser interpretados como comunidades, chamados de módulos da rede. Pode-se definir a modularidade (Q) de um grafo conexo por

$$Q = \frac{1}{2|\mathcal{E}|} \sum_{i,j} \left[a_{i,j} - \frac{C_{deg}(v_i)C_{deg}(v_j)}{2|\mathcal{E}|} \right] \gamma(c_i, c_j) \quad (16)$$

em que $|\mathcal{E}|$ é número total de arestas do grafo, $C_{deg}(v_x)$ é o grau do nó v_x , que em um grafo ponderado é o peso total das arestas conectadas ao nó v_x , $a_{i,j}$ é o peso da aresta entre v_i e v_j . O nó v_x faz parte da comunidade c_x e há uma função indicadora $\gamma(c_i, c_j)$ que assume valor unitário, se $c_i = c_j$, e é nula, se $c_i \neq c_j$, ou seja, a função indicadora é igual a 1 se os nós v_i e v_j estão na mesma comunidade. A Figura 1.8 mostra a variação da modularidade de um grafo conexo, considerando diferentes cenários de segregação em comunidades. As cores dos nós representam a comunidade a qual estão associados. Em A, o surgimento de duas comunidades bem definidas e fracamente conectadas entre si, resulta em um valor ótimo de modularidade. Em compensação, em B observa-se uma cenário subótimo de divisão em comunidades. Em C, constata-se a existência de uma única comunidade contendo todos os nós do grafo, implicando uma modularidade nula. Por fim, a modularidade negativa vista em D indica que cada nó do grafo é uma comunidade em si. Observa-se que quanto maior a modularidade da rede, maior a tendência de formar comunidades com forte conectividade entre os membros. A modularidade é capaz de medir o quão forte é a conexão de um nó adicionado a uma comunidade em contraste à sua adição a uma comunidade aleatória. Outros algoritmos empregam o passeio aleatório (*random walk*). No passeio aleatório, a sequência de transições entre nós de um grafo é modelada por uma Cadeia de Markov finita e temporalmente reversível.

Algoritmo *Louvain*

O algoritmo de *Louvain* é uma abordagem heurística não supervisionada que visa maximizar a modularidade a partir de sucessivas redistribuições de nós entre as várias comunidades de um grafo. Assim, o algoritmo Louvain divide-se em 2 fases, otimização da modularidade e agregação de comunidade. Após a otimização da modularidade executa-se a agregação de modularidade. Na fase de otimização da modularidade, o algoritmo ordena os nós aleatoriamente e verifica a modularidade ao remover cada nó de uma comunidade e adicioná-lo em outra comunidade, até que não haja mais um aumento significativo na modularidade. Na fase da agregação de comunidade, todos os nós que pertencem a uma mesma comunidade são fundidos em um único nó representativo dessa comunidade, o nó gigante. Os enlaces que conectam nós gigantes são o conjunto dos enlaces que conectavam os nós que fazem parte do nó gigante. Isso pode gerar auto-laços




Figura 1.8. Variação da modularidade de um grafo conexo, considerando diferentes cenários de segregação em comunidades. As cores dos nós representam a comunidade a qual estão associados. A modularidade diminui do cenário (A) em direção ao cenário (D). Quanto maior a modularidade da rede, maior a tendência de formar comunidades com forte conectividade entre os membros.

(*self-loops*) conectando o nó gigante a ele mesmo. Essas duas fases são repetidas até alcançar a convergência, quando nenhum outro remanejamento de nós proporciona um aumento na modularidade total do grafo. A popularidade do algoritmo é reflexo da sua eficiência, sendo capaz de garantir a rápida construção de comunidades mesmo em redes extremamente populosas [Alatawi et al., 2021].

Fast Greedy

Implementando uma lógica baseada no agrupamento hierárquico aglomerativo, o *Fast Greedy* [Clauset et al., 2004] busca segregar o grafo original em comunidades a partir da otimização da métrica de modularidade. Ao optar pelo método aglomerativo, *i.e.* *bottom-up*, o algoritmo inicia atribuindo uma comunidade única a cada nó do grafo. Guiando-se pelas potenciais alterações na modularidade do grafo, o *Fast Greedy* elege as duas comunidades a serem mescladas de cada iteração. Na prática, o par que fornecer o máximo de melhoria de modularidade é selecionado para compor uma nova comunidade. Tal procedimento é repetido até que nenhuma fusão de pares de comunidade culmine em um aumento na modularidade. A eficiência do algoritmo reflete em um tempo de execução linear mesmo em redes extremamente grandes. Caso a rede analisada apresente uma estrutura esparsa e hierárquica, o algoritmo pode atingir uma complexidade de tempo de $O(|\mathcal{V}| \log^2 |\mathcal{V}|)$, em que \mathcal{V} é o número de nós.

Algoritmo de Propagação de Rótulos

Igualmente rápido na geração de comunidades, o Algoritmo de Propagação de Rótulos (*Label Propagation Algorithm* - LPA) prevê que cada nó deve ser atribuído à mesma comunidade que a maioria de seus vizinhos diretos. Para implementar tal estratégia, o algoritmo normalmente inicializa alocando um rótulo distinto a cada nó do grafo. Em seguida, segundo uma ordem aleatoriamente gerada de nós, o algoritmo executa um processo iterativo em que cada nó recebe o rótulo predominante na sua vizinhança. Essa




Figura 1.9. Princípio de funcionamento do LPA sobre um grafo ponderado. No cenário (A), o algoritmo inicia distribuindo rótulos únicos a cada nó pertencente ao grafo. A cada iteração, o LPA escolhe e processa de forma aleatória cada nó do grafo, atribuindo aos nós o rótulo de seu vizinho com o peso máximo. Esse processo de atualização dos rótulos ocorre entre as várias iterações entre os cenários (B) e (C). A convergência observada no cenário (D) ocorre quando todos os nós obtêm o rótulo majoritário de seus vizinhos ou quando alcance-se o limite máximo de iteração pré-estabelecido.

atualização do rótulo do nó depende do peso máximo, calculado com base nos pesos dos nós vizinhos e seus relacionamentos. Após a convergência do processo, grupos de nós com o mesmo rótulo são interpretados como comunidades [Yang et al., 2016]. Dessa forma, dependendo da ponderação das arestas e do grau de conexão de um nó, seu rótulo pode rapidamente tornar-se dominante em um grupo de nós densamente conectado. Do mesmo modo, este rótulo terá dificuldades para cruzar uma região escassamente conectada.

É possível haver iterações durante a execução do algoritmo em que nós selecionados não tenham seus rótulos atualizados. Isso ocorre devido aos vizinhos com o peso máximo já possuírem o mesmo rótulo que o nó em questão. Além disso, ocorrem empates, ou seja, vizinhos com peso máximo iguais e rótulos diferentes. O empate é resolvido de maneira uniforme e aleatória. Devido a eventuais problemas de convergência, é aconselhável que o LPA seja implementado especificando um limite máximo de iteração. A configuração desse parâmetro evita a ocorrência de ciclos infinitos de trocas de rótulos que impactariam na eficiência do algoritmo. Diferentemente de outros algoritmos, o LPA pode retornar diferentes estruturas de comunidade quando executado várias vezes sob o mesmo grafo. Essa variabilidade de resultados possíveis é influenciada pela ordem com que o LPA avalia os nós, bem como pelo processo de desempate aleatório.

Método de Percolação de Cliques

O Método de Percolação de Cliques (*Clique Percolation Method* - CPM) concentra-se na detecção de comunidades interpretando-as como subgrafos totalmente conectados, os k -cliques. A partir de um valor inteiro pré-estabelecido (k), o método identifica cliques de k nós e os aglutina caso dois cliques compartilhem $k - 1$ nós. Esse processo de identificação e aglutinação de cliques é repetido até que não haja mais junções possíveis [Alsini et al., 2020]. A Figura 1.9.1 mostra exemplos de k -cliques. É




Figura 1.10. Em (A) ilustra-se vários tipos de k -clique. Em (B) mostra-se as diferenças entre clique máximo e maximal em um mesmo grafo. Na prática, um clique máximo é o clique que inclui o maior número possível de nós do grafo. Já um clique maximal é clique que não pode ser aumentado pela inclusão de mais um nó, alcançando assim ápice do seu tamanho. Assim todo clique máximo é maximal, mas o contrário não. Em (C) exemplifica-se as comunidades geradas pelo CPM utilizando $k = 3$. Neste exemplo, o CPM agrupa triângulos (3-clique) mesma comunidade quando estes têm $k - 1$ nós em comum.

importante destacar e diferenciar os conceitos de clique maximal e clique máximo. No processo de aglutinação de cliques, eventualmente não é mais possível aumentar o tamanho de um determinado clique porque ele não é um subconjunto de um clique maior. Um clique máximo é o maior clique da rede, isto é, aquele que possui a maior quantidade de nós. Em decorrência da capacidade de gerar comunidades sobrepostas, o CPM é útil na representação realista de redes sociais, visto que usuários reais podem pertencer a várias comunidades simultaneamente. Em redes sociais reais, a não exclusividade de pertencimento vale tanto para núcleos familiares ou de amizade, quanto para câmaras de eco relacionadas a temas distintos [Alduaiji et al., 2018]. A lógica simples do CPM garante também uma rapidez no funcionamento. O CPM pode ser aplicado a grafos ponderados ou não ponderados.

WalkTrap

O algoritmo *WalkTrap* [Pons e Latapy, 2005] fundamenta-se na premissa de que passeios aleatórios de curtas distâncias tendem a permanecer na mesma comunidade. Como o *Fast Greedy*, o algoritmo *Walktrap* aplica uma lógica baseada no agrupamento hierárquico aglomerativo, em que nós, ou agrupamentos de nós, são recursivamente mesclados segundo um critério de união. Para lidar com a alta complexidade computacional de encontrar as comunidades ótimas, é possível empregar uma abordagem de Monte Carlo na estimação das probabilidades para os passeios aleatórios. Destaca-se que o algoritmo *Walktrap* atribui apenas uma comunidade a cada nó e, dessa forma, não há sobreposição entre as comunidades.

O algoritmo *WalkTrap* computa uma matriz de probabilidades de transição a partir de uma matriz de adjacências. Cada elemento da matriz de transição representa a probabilidade do passeio continuar para o nó adjacente com base na intensidade da relação entre os nós. Utiliza-se um processo de passeio aleatório com uma quantidade pequena

de passos para definir a probabilidade de transição entre um nó v_i e um nó v_j . Essa probabilidade é influenciada pelo grau do nó v_j de forma que existe uma maior probabilidade de transicionar para um nó com maior grau. A probabilidade de transição também é maior quando os nós v_i e v_j estão na mesma comunidade. Os passeios aleatórios definem uma distância entre os nós que é, então, generalizada para distância entre comunidades. Considera-se um passeio aleatório que se inicia em uma comunidade a partir de um nó inicial escolhido aleatoriamente e uniformemente dentre os nós da comunidade. Define-se a probabilidade de transição de partir de uma comunidade c para um nó v_j em t passos, a fim de encontrar a distância entre comunidades. Inicialmente, existem $|\mathcal{V}|$ comunidades, uma para cada nó. Computa-se todas as distâncias entre os nós adjacentes. Dados k passos, duas comunidades são escolhidas de acordo com um critério, essas duas comunidades são fundidas e as distâncias entre as comunidades atualmente existentes são computadas. Após $|\mathcal{V}| - 1$ passos, o algoritmo termina. O objetivo é minimizar a média das distâncias quadradas entre cada nó e a comunidade à qual pertence. A modularidade é normalmente usada para determinar a divisão ótima entre as comunidades.

InfoMap

O algoritmo *InfoMap* foca na otimização da equação de mapa (*map equation*) [Rosvall et al., 2009], uma equação que busca minimizar o comprimento da sequência usada para representar um passeio no grafo. Essa minimização é alcançada empregando a codificação de Huffman, um tipo de codificação sem perdas que garante que os nós mais visitados sejam representados por um número menor de bits. Para minimizar o comprimento da caminhada, o grafo pode ser dividido em diferentes módulos, onde cada módulo possui seu próprio livro de códigos (*codebook*). Há também um livro de códigos que representa o movimento entre os módulos (livro de códigos de índice). O comprimento da descrição de um módulo pode ser representado pela equação do mapa:

$$L(M) = q_{\sim} H(Q) + \sum_{l=1}^M p^l H(P^l), \quad (17)$$

em que a primeira parte é a entropia do movimento entre as comunidades e a segunda parte é a entropia dos movimentos dentro das comunidades. As comunidades detectadas pela equação de mapa podem eventualmente divergir daquelas identificadas por algoritmos baseados na maximização da modularidade. Isso ocorre porque o cerne da equação de mapa está em otimizar o fluxo de informações, enquanto a modularidade baseia-se na conexão entre nós.

1.9.2. Métricas de Avaliação Extrínsecas e Intrínsecas

O processo de avaliação dos algoritmos de detecção de comunidade pode ser conduzido por meio de duas classes de métricas, as intrínsecas e as extrínsecas. Embora sejam igualmente úteis, a diferença entre ambas está na exigência, ou não, de uma verdade fundamental (*ground truth*), isto é, um rótulo de verdade fundamental atribuído a cada amostra. Tal rótulo funciona como base de comparação entre o resultados esperado e o obtido. Em um cenário de detecção de câmaras de eco, esses rótulos podem expressar qual comunidade, *i.e.* câmara de eco, um usuário participa. As métricas extrínsecas

requerem obrigatoriamente a presença de amostras rotuladas, sendo portanto capazes de comparar o desempenho entre métodos. Na ausência de *ground truth*, muitos autores inferem o pertencimento, ou não, de um usuário a uma câmara de eco por meio da análise das *hashtags* compartilhadas. Apesar de subjetiva, essa inferência evita que a descoberta do rótulo de cada usuário seja dependente da análise textual com técnicas possivelmente mais demoradas e complexas de processamento de linguagem natural e aprendizado de máquina. Logo, pode-se inferir a qual comunidade um determinado usuário pertence, avaliando a ocorrência de *hashtags* em suas postagens. Além das medidas de recuperação da informação, *e.g.* acurácia, precisão, revocação, entre outras, as métricas extrínsecas também incluem:

- **Rand Index (RI)** que é um índice que expressa a similaridade entre os resultados previstos e os reais a partir da contabilização dos pares de amostras atribuídos na mesma ou em comunidades diferentes. Assumindo que $\mathcal{C} = \{c_1, \dots, c_i\}$ é o conjunto das i comunidades retornadas pelo algoritmo de detecção de comunidade e $\mathcal{K} = \{k_1, \dots, k_j\}$ é o conjunto das i comunidades de *ground truth*, o índice é dado por

$$RI(\mathcal{X}, \mathcal{Y}) = \frac{2(a+b)}{n(n-1)}, \quad (18)$$

em que n é o número de amostras, a expressa o número de pares de amostras que mantiveram-se na mesma comunidade em \mathcal{X} e \mathcal{Y} , e b é o número de pares de amostras que foram alocadas em comunidades diferentes em \mathcal{X} e \mathcal{Y} . A métrica é definida entre $[0, 1]$, em que 0 indica que os dois resultados previstos e reais não concordam em nenhum par de amostras e 1 reflete a completa concordância entre os dois resultados. O Adjusted Rand Index, uma versão corrigida e simétrica da métrica original, introduz uma normalização estatisticamente induzida para produzir valores próximos de zero para partições aleatórias.

- **Informação Mútua Normalizada (NMI)** que é a métrica derivada da informação mútua que é calculada entre os rótulos de *ground truth* e os rótulos previstos. Para tal, considera-se que $\mathcal{X} = \{X_1, \dots, X_n\}$ é o conjunto de rótulos das comunidades originalmente atribuídas às n amostras, enquanto $\mathcal{Y} = \{Y_1, \dots, Y_n\}$ é o conjunto de rótulos das comunidades atribuídas às n amostras após a aplicação de um algoritmo. Ao tratar \mathcal{X} e \mathcal{Y} como variáveis aleatórias discretas, a informação mútua normalizada entre ambas é expressa por

$$NMI(\mathcal{X}, \mathcal{Y}) = \frac{2I(\mathcal{X}; \mathcal{Y})}{H(\mathcal{X}) + H(\mathcal{Y})}, \quad (19)$$

em que $I(\mathcal{X} : \mathcal{Y})$ é a informação mútua entre \mathcal{X} e \mathcal{Y} e as entropias de \mathcal{X} e \mathcal{Y} são denotadas por $H(\mathcal{X})$ e $H(\mathcal{Y})$, respectivamente.

A escassez de conjuntos de dados previamente rotulados e a dificuldade de rotulagem frequentemente inviabilizam a utilização de métricas de avaliação extrínsecas. Dessa forma, cabe uma avaliação baseada em medidas intrínsecas, também chamadas de índices de validação de agrupamento, para quantificar a coesão e separação das comunidades geradas [Curiskis et al., 2020]. Dentre essas métricas, há:

- **Calinski-Harabasz Index (CH)** que é uma razão entre a dispersão dentro da comunidade e a dispersão entre as comunidades. Na prática, tais dispersões são obtidas através da soma de quadrados entre comunidades (SSB_c) e da soma de quadrados dentro de comunidades (SSW_c) expressos respectivamente pelas equações:

$$SSB_c = \sum_{j=1}^{|\mathcal{N}|} \|x_j - b_{c_j}\|^2 \quad (20) \quad SSB_c = \sum_{i=1}^{|\mathcal{C}|} \|b_i - \bar{X}\|^2, \quad (21)$$

em que $|\mathcal{N}|$ é o tamanho do conjunto das amostras x_i , com $i = 1, \dots, |\mathcal{N}|$ e $|\mathcal{C}|$ denota o número de comunidades. Os centróides das comunidades são denotados como b_i , em que $i = 1, \dots, |\mathcal{C}|$. Adicionalmente, cada amostra x_j pertence a uma comunidade c_j cujo centroide é denotado por b_{c_j} . Diante disso, a métrica pode ser computada através da equação

$$CH = \frac{SSB_c}{SSW_c} \cdot \frac{|\mathcal{N}| - |\mathcal{K}|}{|\mathcal{K}| - 1}. \quad (22)$$

Ao contrário do índice anterior, quanto maior o valor obtido, melhor a qualidade das comunidades geradas.

- **Densidade de Partição (D_p)** que é uma particularização da métrica da densidade tradicional, que considera a compacidade das partições geradas, ou seja, das comunidades. Essa métrica é expressa por

$$D_p = \frac{2}{m} \sum_{\alpha=1}^{|\mathcal{C}|} \frac{m_\alpha - (n_\alpha - 1)}{(n_\alpha - 2)(n_\alpha - 1)}, \quad (23)$$

em que m_α e n_α são o número de arestas e vértices na comunidade $c_\alpha \in \mathcal{C}$, respectivamente.

- **Davies-Bouldin Index (DB)** que é um índice que fornece uma estimativa do grau de sobreposição do agrupamento. É definido como a medida de similaridade média de cada comunidade com seu par mais semelhante, em que a similaridade é a razão entre as distâncias dentro da comunidade e as distâncias entre as comunidades. Considerando $|\mathcal{C}|$ o número de comunidades, o índice é dado por

$$DB = \frac{1}{|\mathcal{C}|} \sum_{i=1}^{|\mathcal{C}|} \max_{i:j \neq i} \frac{S_i + S_j}{d_{i,j}}, \quad (24)$$

em que $S_i = \frac{1}{|c_i|} \sum_{x_j \in c_i} \|x_j - v_i\|$ é a medida de espalhamento dentro da comunidade c_i , x_j é um vetor de dimensão n atribuído à comunidade c_i , e $d_{i,j} = \|v_i - v_j\|$ é a distância euclidiana entre os centroides das comunidades c_i e c_j . Ao considerar o pior cenário de similaridade para cada comunidade, espera-se que quanto mais próximo de zero, o valor mínimo, melhor será o índice e, conseqüentemente, melhores serão os resultados do processo de agrupamento;

- **Coefficiente da Silhueta (SC)** que é um coeficiente que quantifica a qualidade do agrupamento de dados com base na proximidade e na separação entre as comunidades geradas. Conforme evidenciado na Equação 25, o coeficiente da silhueta é medido em função da média dos valores da silhueta de cada amostra do conjunto de dados. Definida entre $[-1, +1]$, a silhueta $s(i)$ para cada amostra i pode ser computada através da Equação 26.

$$SC = \frac{1}{n} \sum_{i=1}^n s(i) \quad (25) \quad s(i) = \frac{\bar{b}(i) - \bar{a}(i)}{\max(\bar{a}(i), \bar{b}(i))} \quad (26)$$

Na Equação 26, $\bar{a}(i)$ representa a distância média entre a amostra i em relação a todas as amostras pertencentes à mesma comunidade e $\bar{b}(i)$ reflete a distância média entre a amostra i em relação a todas as amostras. Em uma perspectiva local, o $s(i)$ avalia a adequação de cada amostra individualmente. Nesse contexto, valores próximos a 1 expressam que a amostra observada encontra-se distante das comunidades vizinhas, indicando que essa amostra foi adequadamente alocada na comunidade à qual pertence. Valores nulos indicam que a amostra localiza-se no limite ou muito próximo do limite de decisão entre duas comunidades adjacentes. Em compensação, valores negativos indicam que a amostra foi possivelmente atribuída a uma comunidade errada. Em uma perspectiva global, o SC traduz a qualidade do agrupamento em comunidades considerando todas o conjunto de amostras. Assim, quanto mais próximo a 1, melhor a adequação de todas as amostras às comunidades a que pertencem. De maneira oposta, valores negativos informam que o processo de agrupamento não foi adequado. A Figura 1.11 mostra graficamente os reflexos no valor da silhueta quando adotando uma divisão em comunidades não ótima.

1.10. Ferramentas de Caracterização de Câmaras de Eco

Embora seja desafiadora, a análise de câmaras de eco suscita diversas oportunidades de pesquisa devido à prevalência dessas estruturas nas mídias sociais em várias plataformas. Estimativas apontam que a fonte dos desafios decorrentes das câmaras de eco é o fato de que as câmaras de eco têm muitos participantes distintos: i) os membros da câmara de eco, ii) as plataformas de mídia social e iii) o mundo “*offline*”. Cada um desses participantes apresenta desafios e problemas em aberto para serem resolvidos. A existência do elemento humano nas câmaras de eco tornam o estudo dessas estruturas desafiador. Trabalhos relacionados a câmaras de eco e polarização devem considerar como as pessoas dentro da câmara de eco consomem conteúdo, percebem o mundo e veem pessoas externas à câmara de eco. Os membros da câmara de eco têm quatro características críticas que contribuem para dificultar a análise dessas estruturas: i) eles não estão cientes de que fazem parte da câmara de eco; ii) eles selecionam apenas conteúdos que aderem às suas crenças; iii) resistem a qualquer informação que refute suas crenças; iv) desconfiam de qualquer ajuda que venha de fora da sua câmara de eco. Aumentar a conscientização sobre as câmaras de eco e seus efeitos no indivíduo e na sociedade é um passo essencial em direção à dissolução de câmaras de eco nocivas. A apresentação das informações que levam os indivíduos para fora de suas câmaras de eco e para uma presença *online* mais civilizada e diversa é fundamental [Alatawi et al., 2021].

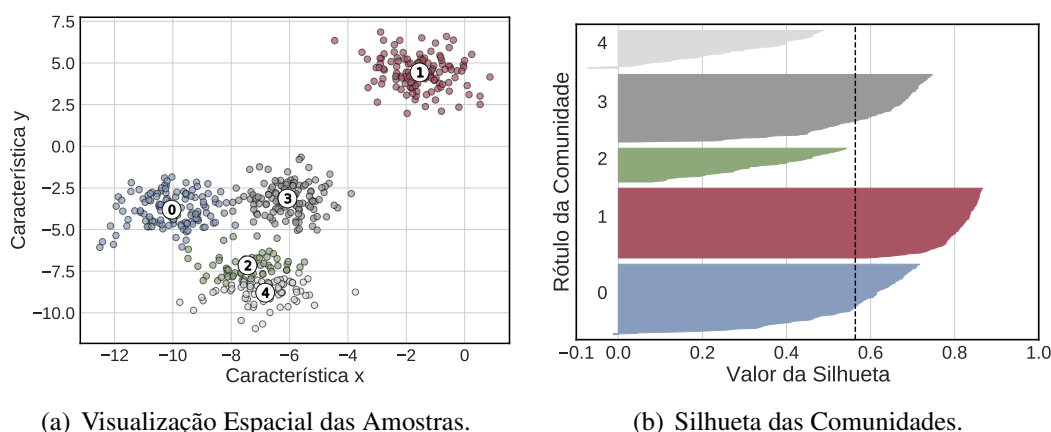


Figura 1.11. Valores da silhueta para um conjunto de dados dividido em cinco comunidades. Em 1.11(a) percebe-se que as comunidades 2 e 4 estão muito próximas entre si, fato que contribui para o baixo valor da métrica nessas comunidades. Em 1.11(b) mostra-se que cada silhueta, *i.e.*, manchas coloridas, tem comprimento horizontal e espessura diretamente proporcionais ao valor da silhueta das amostras associadas e à quantidade de amostras na comunidade, respectivamente. Em um cenário ideal de agrupamento em comunidades, o valor da silhueta correspondente a cada comunidade deve ser maior que o valor médio dos coeficientes de silhueta (linha pontilhada preta). Além disso, espera-se que nesse cenário as espessuras de cada silhueta sejam semelhantes entre si.

Desenvolvida por Gillani *et al.*, a **Social Mirror**¹⁴ é um aplicação *web* que permite aos usuários explorarem, de forma interativa, suas conexões politicamente ativas no *Twitter* [Gillani et al., 2018]. Tais conexões são visualmente modeladas na forma de um grafo, em que os nós representam um conjunto de contas participantes de um debate específico e as arestas representam uma relação de amizade mútua entre as contas. Internamente, a *Social Mirror* emprega o *PageRank* e um classificador de ideologia política para embasar o dimensionamento dos nós e atribuir uma tonalidade a eles. Ao apresentar uma visão panorâmica da fração mais ideologicamente fragmentada da rede do usuário, a ferramenta visa inspirar a autorreflexão e motivar o compartilhamento de conteúdo mais diversificado entre usuários.

O **ChamberBreaker** [Jeon et al., 2021] é um sistema baseado em jogos, projetado para aumentar as capacidades cognitivas dos jogadores a fim de torná-los mais aptos a responderem preventivamente ao surgimento de câmaras de eco. Dentro do *ChamberBreaker*, cada jogador torna-se um usuário anônimo da rede social e é induzido a compartilhar continuamente *tweets* tendenciosos que fomentam a criação de uma câmara de eco. O sistema integra conceitos psicológicos e disponibiliza diferentes temas, cada um abordando uma característica específica das câmaras de eco. Dentre os benefícios do sistema aos seus usuários pode-se citar o aumento das intenções pelo consumo de informações com perspectivas mais diversas, bem como a elevação da conscientização sobre os efeitos negativos do fenômeno da câmara de eco.

Focando na redução do consumo de mídia partidária, **Balancer** [Munson et al.,

¹⁴Disponível em <https://socialmirror.media.mit.edu>.

2013] é uma aplicação curta para navegador (*widget*) que exhibe aos usuários se seu histórico de leitura é consistente com um padrão de leitura ideologicamente balanceado. Ao medir continuamente essa inclinação, prova-se que a ferramenta promove melhorias, mesmo que pequenas, nos hábitos de leitura enviesados politicamente. Em um estudo de campo, usuários relatam mais visitas a páginas *web* ideologicamente opostos e centristas.

Para quantificar a força da câmara de eco à qual o usuário pertence, o **Check-my-echo** [Bail et al., 2018] analisa previamente a orientação política proeminente das contas que o usuário segue, sejam elas de políticos eleitos, jornalistas ou grupos de defesa de temas específicos. Tal análise aplica um algoritmo de particionamento recursivo para encontrar padrões de conexão entre líderes de opinião e autoridades eleitas de diferentes inclinações políticas. Assim, ao efetuar o *login* no *Twitter* através da ferramenta, o usuário consegue descobrir sua pontuação média na escala de 0 a 10 de inclinação política. Valores próximos ao limite inferior indicam um caráter mais liberal, enquanto que valores próximo ao limite superior refletem um cunho mais conservador. A assertividade da ferramenta é maior para usuários dos Estados Unidos, visto que os líderes de opinião usados como base de comparação são do cenário político estadunidense.

Ao investigar o surgimento das câmaras de eco, Sasahara *et al.* desenvolvem um modelo simples de compartilhamento de informações em redes sociais *online* [Sasahara et al., 2021]. Na prática o modelo retrata o comportamento do usuário quando continuamente exposto a mensagens semelhantes endossadas por amigos. Para facilitar a exploração do modelo, os autores desenvolvem uma demonstração interativa¹⁵ que permite executar simulações ajustando três parâmetros-chave: i) a tolerância, relacionada a como o usuário lida com diferentes opiniões; ii) a influência social, que controla o quão rápido a opinião do usuário pode ser atualizada; e iii) o *unfriending*, que regula a frequência do ato de desfazer amizades. A demonstração evidencia que o processo de evolução das câmaras de eco atinge um estado estacionário, caracterizado por dois aspectos distintos, a polarização de opinião e a segregação da rede.

1.11. Atividade Prática

Esta seção consolida a pluralidade de conceitos teóricos abordados no capítulo através de uma atividade prática do processo de estruturação, caracterização e detecção de câmaras de eco em redes sociais. O processo ocorre na rede social *Twitter* e é representado na Figura 1.11. O processo é totalmente desenvolvido na linguagem *Python* e inclui quatro etapas contendo seis tarefas: i) coleta de informações textuais relacionadas a usuários potencialmente integrantes de câmaras de eco, empregando a interface de programação de aplicação (*Application Programming Interface* - API) do *Twitter* para efetuar o *web scraping*; ii) estruturação de grafos relacionais com base nos dados coletados dos usuários; iii) caracterização do grafo gerado segundo métricas de redes complexas; iv) aplicação eficiente de algoritmos de detecção de comunidade; v) execução de um método de incorporação de grafos a fim de gerar uma representação vetorial densa do grafo criado; e vi) avaliação da eficiência e qualidade da detecção, tendo como parâmetros os índices de validação de agrupamento.

A primeira etapa da atividade prática consiste em exemplificar a tarefa de cons-

¹⁵Disponível em <https://osome.iu.edu/demos/echo/>.

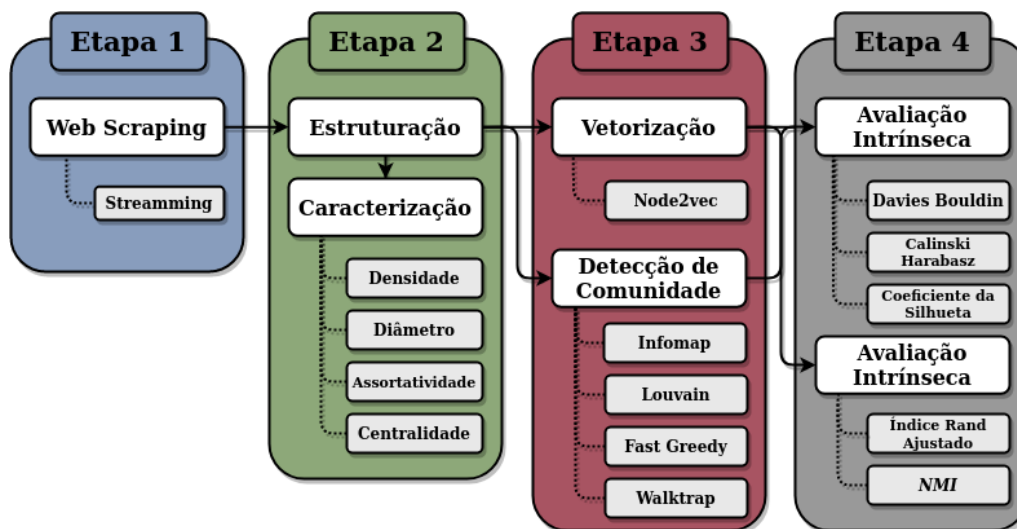


Figura 1.12. Fluxograma do processo de detecção de câmaras de eco desenvolvido na atividade prática. A primeira etapa compreende a coleta de dados no *Twitter* para construir uma base de dados. A segunda etapa prevê a estruturação dos dados em um grafo relacional para ser caracterizado por métricas de redes complexas. Na terceira etapa, o grafo é submetido a uma técnica de incorporação e a diferentes algoritmos de detecção de comunidade. A quarta etapa avalia a qualidade da detecção através de métricas intrínsecas e extrínsecas.

trução de uma base de dados relacionada à câmaras de eco, a partir do *web scraping* do *Twitter*. Contudo, como descrito na Seção 1.5, a estratégia de construção mais difundida na literatura é através da captura de postagens sobre tópicos controversos. Além de favorecer a polarização de opiniões, um tópico controverso costuma ser intensamente debatido nas redes sociais, gerando um alto engajamento e consequentemente dados para coleta. Perante essas observações, a atividade prática opta pelo uso de uma palavra-chave para nortear o processo de aquisição de dados. Para automatizar o processo de obtenção dos *tweets* relacionados à palavra-chave selecionada, adota-se um *script*¹⁶ em *Python* que acessa a API do *Twitter* usando credenciais de desenvolvedor. Em posse dessas credenciais, a biblioteca **Tweepy**¹⁷ permite a extração de conteúdo textual dos *tweets* de qualquer perfil aberto na rede social segundo duas abordagens. A primeira abordagem destina-se à captura de metadados históricos, postados até o momento de execução do *script*. Apesar da simplicidade e do imediatismo da coleta, a abordagem enfrenta duas limitações impostas pelo *Twitter*, uma temporal e outra quantitativa. A limitação temporal remete a um número máximo de requisições passíveis de serem direcionadas à plataforma a cada janela de tempo de 15 minutos. Paralelamente, há uma limitação na quantidade de *tweets* históricos passíveis de serem coletados. Dependendo da permissão vinculada às credenciais, a obtenção de *tweets* é restringida a um período de até, no máximo, alguns meses passados a contar pela data de execução do *script*. Ciente dessas limitações e visando a dinamicidade e contemporaneidade da captura, a atividade prática foca na segunda abordagem de coleta. Diferentemente da anterior, essa abordagem prevê a captura ininterrupta do fluxo de *tweets* relacionado à palavra-chave, publicados a partir do momento de execução

¹⁶Disponível em <https://github.com/nicollasro/Echochamber>.

¹⁷Disponível em <https://www.tweepy.org/>.

do *script*. Logo, quaisquer *tweets* futuros publicados contendo a palavra-chave adotada, serão coletados.

Diante da ampla variedade de campos retornáveis pela coleta em fluxo contínuo de *tweets*, é recomendado que estes dados sejam adequadamente organizados para análises subsequentes. Para esse propósito, utiliza-se o **Pandas**¹⁸, uma biblioteca capaz de prover a manipulação e alocação em memória de dados a partir de duas estruturas de dados primárias: *Series*, indicada para conjuntos de dados unidimensionais; e *Dataframes*, destinada a conjuntos de dados bidimensionais. Embora a atividade prática exemplifique a tarefa de coleta de dados utilizando o *web scraping*, a formação de uma base de dados contundente pode demorar algumas horas dependendo do tópico e da estabilidade da conexão. Por esta razão, opta-se pela utilização de um base de dados previamente processada e correlacionada. Essa base de dados¹⁹ foi originalmente consolidada por Morini *et al.* e contém três conjuntos de dados relacionados a câmaras de eco [Morini *et al.*, 2021]. Cada conjunto foi construído monitorando uma questão sociopolítica durante cinco semestres consecutivos²⁰, resultando assim em cinco *snapshots* semestrais do período total.

A segunda etapa da atividade prática compreende a estruturação dos dados em grafos relacionais seguida da caracterização dos mesmos. Utiliza-se um segundo *script* em *Python* para realizar as tarefas necessárias. Em *Python*, a criação de estruturas em grafo é facilmente implementável por funções das bibliotecas **igraph**²¹ ou **NetworkX**²². Por ser implementado na linguagem C, o *igraph* detém um desempenho consideravelmente superior ao de bibliotecas puramente desenvolvidas em *Python*, como é o caso da *NetworkX*. Além disso, o *igraph* dispõe de uma gama maior de algoritmos de detecção de comunidade nativamente implementados. Em compensação, a *NetworkX* possui uma documentação mais detalhada e uma comunidade *online* mais ativa. Devido a esses fatores, a atividade prática emprega ambas as bibliotecas de forma complementar, destinando à *NetworkX* as tarefas de estruturação e caracterização, enquanto a *igraph* é usada na tarefa de detecção de comunidades.

Dentre as formas de construir um grafo na *NetworkX*, a mais comum inicia com a criação do objeto referente ao grafo a partir de uma classe. A fim de reproduzir uma rede que expresse as relações de amizade entre usuários, por exemplo, pode-se utilizar a classe `MultiDiGraph`. Essa classe permite instanciar um grafo direcionado que represente as relações de seguidor (*follower*) e seguindo (*following*) entre usuários. Na prática, a inclusão de nós e suas respectivas arestas ponderadas pode ser alcançada através das funções `add_nodes` e `add_weighted_edges_from`. Embora utilizem classes distintas (`Graph`, `DiGraph` ou `MultiGraph`), a mesma lógica aplica-se na criação de grafos de *retweets* e nos grafos de menções entre usuários. Uma vez estruturado, o grafo gerado pode ser submetido a uma caracterização estrutural segundo varias métricas de redes complexas. Através de funções como `diameter` e `density`, pode-se mensurar o diâmetro e a densidade. Adicionalmente, a função `degree_assortativity_coefficient` permite medir a assortatividade do grafo considerando o grau dos nós como característica.

¹⁸Disponível em <https://pandas.pydata.org/>.

¹⁹Disponível em https://github.com/virgiiim/EC_Reddit_CaseStudy.

²⁰Detalhes estruturais sobre o conjunto de dados estão expressos na Tabela 1.3.

²¹Disponível em <https://igraph.org/python/>.

²²Disponível em <http://networkx.lanl.gov/>.

Um dos objetivos da terceira etapa é demonstrar a tarefa de vetorização utilizando incorporação de grafos. Essa tarefa é executado pelo **PecanPy**²³, uma implementação do *Node2vec* rápida, paralelizada, eficiente em memória e otimizada para usar memória cache [Liu e Krishnan, 2021]. O PecanPy opera principalmente em três modos distintos, cada um otimizado para redes com características de tamanho e densidade específicas. Em especial, o modo `PreComp` destina-se a redes pequenas, ou seja, àquelas contendo menos que 10k nós, independente da densidade. Essa limitação estrutural é derivada da computação e armazenamento antecipados de todas as probabilidades de transição de segunda ordem do grafo original. O modo `SparseOTF` é indicado para redes grandes e esparsas, compostas preferencialmente por um número de nós inferior a 10k e possuindo até 10% de arestas possíveis. Em contrapartida, o modo `DenseOTF` foca no processamento de redes grandes e densas, aquelas contendo mais de 10k nós e mais que 10% das arestas possíveis. Para lidar com redes de grandes proporções, ambos os modos calculam as probabilidades de transição de segunda ordem *On-The-Fly* (OTF) durante a geração de passeios aleatórios, sem salvá-las. Além da redução do custo de memória, essa otimização evita o desperdício computacional atrelado ao cálculo de probabilidades de transição de segunda ordem que eventualmente nunca seriam utilizadas na geração de passeios. Além da seleção do modo de operação, o Pecanpy permite configurar o tamanho do vetor incorporado de saída.

A terceira etapa também demonstra a tarefa de execução de alguns algoritmos de detecção de comunidade, sendo eles *Infomap*, *Louvain*, *Fast Greedy* e *Walktrap*. A escolha dos algoritmos tem a finalidade de diversificar os resultados gerados, uma vez que cada algoritmo utiliza uma métrica base ou lógica específica de funcionamento. Embora admitam a configuração de outros parâmetros opcionais, todos esses algoritmos requerem obrigatoriamente um grafo previamente estruturado como parâmetro de entrada. Como saída, cada algoritmo retorna o rótulo da comunidade atribuído a cada nó. Após obter as saídas de ambas as tarefas de vetorização e detecção de comunidades, segue-se para a etapa de avaliação.

Na quarta e última etapa da atividade prática, diversas funções e classes de módulos específicos da biblioteca **Scikit-learn**²⁴ são empregadas na avaliação das comunidades, *i.e.* câmaras de eco, detectadas. Ao incluir algumas funções do módulo `Metrics` ao *script* desenvolvido, pode-se implementar métricas intrínsecas e extrínsecas de avaliação. Em especial, funções como `calinski_harabasz_score`, `davies_bouldin_score` e `silhouette_score` permitem avaliar o quão compactas e sobrepostas são as comunidades geradas, retornando os valores dos índices Calinski-Harabasz e Davies-Bouldin e do Coeficiente da Silhueta. Aproveitando a existência de um conjunto de dados pré-rotulado, pode-se também avaliar extrinsecamente os resultados através de funções como `adjusted_rand_score` e `normalized_mutual_info_score`. Tais funções retornam respectivamente os valores do índice Rand Ajustado e da Informação Mútua Normalizada entre os rótulos obtidos e os de referência. Ao final da atividade, evidenciam-se os diferentes resultados obtidos pelos algoritmos de detecção de comunidade adotados, tanto numa perspectiva quantitativa quanto visual. A visualização dos resultados é realizada por meio de funções

²³Disponível em <https://github.com/krishnanlab/PecanPy>.

²⁴Disponível em <https://scikit-learn.org/stable/>.

da biblioteca **Matplotlib**²⁵ capaz de exibir gráficos em múltiplos formatos.

1.12. Considerações Finais

Este minicurso investiga as câmaras de eco (*echo chamber*), um fenômeno relacionado às estruturas sociais homogêneas cujos membros excluem sistematicamente opiniões, crenças e fontes de informação que diverjam daquelas disseminadas entre eles. Para mitigar equívocos semânticos a respeito do tema, busca-se inicialmente descrever as definições e características das câmaras de eco e dos principais termos correlatos. O minicurso pauta-se na metodologia PRISMA para reunir 30 publicações relacionadas à detecção e caracterização de câmaras de eco. Tais trabalhos compõem a base do conteúdo técnico detalhado ao longo do minicurso. Dentre as duas principais abordagens de identificação de câmaras de eco em redes sociais, o minicurso adentra nos procedimentos e técnicas empregadas na abordagem topológica. A abordagem topológica visa detectar câmaras de eco segundo um viés estrutural, o qual busca padrões de conexão característicos de usuários pertencentes a essas estruturas ressoantes de informação. Durante a descrição das principais etapas no processo de detecção, o minicurso inicialmente relata a construção de uma base de dados relacionada a câmaras de eco a partir da coleta automática de postagens sobre um tópico controverso. Após a coleta, informações específicas podem ser extraídas e correlacionadas em uma estrutura em grafo. Essa estruturação permite que a tarefa de identificação de câmaras de eco seja interpretada como um problema de descoberta de comunidades em grafos. Como consequência direta dessa associação, pode-se caracterizar estruturalmente as câmaras de eco empregando tanto métricas genéricas de redes complexas, quanto métricas específicas como a controvérsia. Sendo o cerne do processo de identificação de câmaras de eco, os algoritmos de detecção de comunidade são vastamente explorados no minicurso, em que suas lógicas de funcionamento, aplicabilidade e complexidade são descritas. Paralelamente, o minicurso debate os principais modelos de vetorização com ênfase nas técnicas de incorporação de grafos. Ao abordar diferentes cenários de avaliação, o minicurso inclui métricas extrínsecas que são dependentes de uma verdade fundamental (*ground truth*), assim como métricas intrínsecas que são independentes desse rótulo de referência. Ambientada no *Twitter*, a atividade prática desenvolvida mostra em detalhes a viabilidade da detecção de câmaras de eco utilizando técnicas computacionais. Diante disso, o minicurso apresenta diversos conceitos sociais e técnicos que permeiam as câmaras de eco no âmbito de redes sociais *online*. Assim, este minicurso fomenta a análise crítica e motiva pesquisadores a desenvolver soluções que auxiliem na identificação e prevenção de câmaras de eco em redes sociais, mitigando assim os seus efeitos danosos. Vale ressaltar que promover a interação saudável entre usuários de redes sociais *online* é uma responsabilidade conjunta da comunidade científica, formuladores de políticas digitais, administração e da sociedade em geral.

Referências

[Ahmed et al., 2013] Ahmed, A., Shervashidze, N., Narayanamurthy, S., Josifovski, V. e Smola, A. J. (2013). Distributed large-scale natural graph factorization. Em *Proceedings of the 22nd International Conference on World Wide Web*, p. 37–48.

²⁵Disponível em <https://matplotlib.org/>.

- [Alatawi et al., 2021] Alatawi, F., Cheng, L., Tahir, A., Karami, M., Jiang, B., Black, T. e Liu, H. (2021). A survey on echo chambers on social media: Description, detection and mitigation. *arXiv preprint arXiv:2112.05084*.
- [Alduaiji et al., 2018] Alduaiji, N., Datta, A. e Li, J. (2018). Influence propagation model for clique-based community detection in social networks. *IEEE Transactions on Computational Social Systems*, 5(2):563–575.
- [Alsini et al., 2020] Alsini, A., Datta, A. e Huynh, D. Q. (2020). On utilizing communities detected from social networks in hashtag recommendation. *IEEE Transactions on Computational Social Systems*, 7(4):971–982.
- [Bail et al., 2018] Bail, C. A., Argyle, L. P., Brown, T. W., Bumpus, J. P., Chen, H., Hunzaker, M. F., Lee, J., Mann, M., Merhout, F. e Volfovsky, A. (2018). Exposure to opposing views on social media can increase political polarization. *Proceedings of the National Academy of Sciences*, 115(37):9216–9221.
- [Bakshy et al., 2015] Bakshy, E., Messing, S. e Adamic, L. A. (2015). Exposure to ideologically diverse news and opinion on facebook. *Science*, 348(6239):1130–1132.
- [Barabási, 2016] Barabási, A.-L. (2016). *Network Science*. "Cambridge University Press".
- [Barberá et al., 2015] Barberá, P., Jost, J. T., Nagler, J., Tucker, J. A. e Bonneau, R. (2015). Tweeting from left to right: Is online political communication more than an echo chamber? *Psychological science*, 26(10):1531–1542.
- [Baumann et al., 2020] Baumann, F., Lorenz-Spreen, P., Sokolov, I. M. e Starnini, M. (2020). Modeling echo chambers and polarization dynamics in social networks. *Phys. Rev. Lett.*, 124:048301.
- [Belkin e Niyogi, 2001] Belkin, M. e Niyogi, P. (2001). Laplacian eigenmaps and spectral techniques for embedding and clustering. *Advances in Neural Information Processing Systems*, 14.
- [Bessi, 2016] Bessi, A. (2016). Personality traits and echo chambers on facebook. *Computers in Human Behavior*, 65:319–324.
- [Bessi et al., 2015] Bessi, A., Zollo, F., Del Vicario, M., Scala, A., Caldarelli, G. e Quattrociocchi, W. (2015). Trend of narratives in the age of misinformation. *PloS one*, 10(8):e0134641.
- [Cao et al., 2015] Cao, S., Lu, W. e Xu, Q. (2015). Grarep: Learning graph representations with global structural information. Em *Proceedings of the 24th ACM International on Conference on Information and Knowledge management*, p. 891–900.
- [Cao et al., 2016] Cao, S., Lu, W. e Xu, Q. (2016). Deep neural networks for learning graph representations. Em *Proceedings of the AAAI Conference on Artificial Intelligence*, volume 30.

- [Chitra e Musco, 2020] Chitra, U. e Musco, C. (2020). Analyzing the impact of filter bubbles on social network polarization. Em *Proceedings of the 13th International Conference on Web Search and Data Mining*, p. 115–123.
- [Cinelli et al., 2021] Cinelli, M., De Francisci Morales, G., Galeazzi, A., Quattrociocchi, W. e Starnini, M. (2021). The echo chamber effect on social media. *Proceedings of the National Academy of Sciences*, 118(9):e2023301118.
- [Cinus et al., 2022] Cinus, F., Minici, M., Monti, C. e Bonchi, F. (2022). The effect of people recommenders on echo chambers and polarization. Em *Proceedings of the International AAAI Conference on Web and Social Media*, volume 16, p. 90–101.
- [Clauset et al., 2004] Clauset, A., Newman, M. E. e Moore, C. (2004). Finding community structure in very large networks. *Physical review E*, 70(6):066111.
- [Colleoni et al., 2014] Colleoni, E., Rozza, A. e Arvidsson, A. (2014). Echo chamber or public sphere? predicting political orientation and measuring political homophily in twitter using big data. *Journal of communication*, 64(2):317–332.
- [Conover et al., 2011] Conover, M., Ratkiewicz, J., Francisco, M., Gonçalves, B., Menczer, F. e Flammini, A. (2011). Political polarization on twitter. Em *Proceedings of the International AAAI Conference on Web and Social Media*, volume 5, p. 89–96.
- [Cossard et al., 2020] Cossard, A., De Francisci Morales, G., Kalimeri, K., Mejova, Y., Paolotti, D. e Starnini, M. (2020). Falling into the echo chamber: The italian vaccination debate on twitter. Em *Proceedings of the International AAAI Conference on Web and Social Media*, volume 14, p. 130–140.
- [Cota et al., 2019] Cota, W., Ferreira, S. C., Pastor-Satorras, R. e Starnini, M. (2019). Quantifying echo chamber effects in information spreading over political communication networks. *EPJ Data Science*, 8(1):1–13.
- [Cui et al., 2019] Cui, P., Wang, X., Pei, J. e Zhu, W. (2019). A survey on network embedding. *IEEE Transactions on Knowledge and Data Engineering*, 31(5):833–852.
- [Curiskis et al., 2020] Curiskis, S. A., Drake, B., Osborn, T. R. e Kennedy, P. J. (2020). An evaluation of document clustering and topic modelling in two online social networks: Twitter and reddit. *Information Processing & Management*, 57(2):102034.
- [Dash et al., 2019] Dash, A., Mukherjee, A. e Ghosh, S. (2019). A network-centric framework for auditing recommendation systems. Em *IEEE INFOCOM 2019 - IEEE Conference on Computer Communications*, p. 1990–1998.
- [de Oliveira et al., 2020a] de Oliveira, N. R., Medeiros, D. S. e Mattos, D. M. (2020a). A sensitive stylistic approach to identify fake news on social networking. *IEEE Signal Processing Letters*, 27:1250–1254.
- [de Oliveira et al., 2021a] de Oliveira, N. R., Medeiros, D. S. e Mattos, D. M. (2021a). Caracterização sócio-temporal de conteúdos em redes sociais baseada em processamento em fluxo. Em *Anais do XXVI Workshop de Gerência e Operação de Redes e Serviços*, p. 54–67. SBC.

- [de Oliveira et al., 2020b] de Oliveira, N. R., Pisa, P. S., Costa, B., Lopez, M. A., Moraes, I. M. e Mattos, D. M. (2020b). Processamento de linguagem natural para identificação de notícias falsas em redes sociais: Ferramentas, tendências e desafios. Em *Minicursos do XX Simpósio Brasileiro de Segurança da Informação e de Sistemas Computacionais (SBSeg 2020)*.
- [de Oliveira et al., 2021b] de Oliveira, N. R., Pisa, P. S., Lopez, M. A., de Medeiros, D. S. V. e Mattos, D. M. F. (2021b). Identifying fake news on social networks based on natural language processing: Trends and challenges. *Information*, 12(1).
- [Deffuant et al., 2000] Deffuant, G., Neau, D., Amblard, F. e Weisbuch, G. (2000). Mixing beliefs among interacting agents. *Advances in Complex Systems*, 3(01n04):87–98.
- [Del Vicario et al., 2016] Del Vicario, M., Vivaldo, G., Bessi, A., Zollo, F., Scala, A., Caldarelli, G. e Quattrociocchi, W. (2016). Echo chambers: Emotional contagion and group polarization on facebook. *Scientific reports*, 6(1):1–12.
- [Donkers e Ziegler, 2021] Donkers, T. e Ziegler, J. (2021). The dual echo chamber: Modeling social media polarization for interventional recommending. Em *Fifteenth ACM Conference on Recommender Systems, RecSys '21*, p. 12–22, New York, NY, USA. Association for Computing Machinery.
- [Fletcher et al., 2021] Fletcher, R., Robertson, C. T. e Nielsen, R. K. (2021). How many people live in politically partisan online news echo chambers in different countries? *Journal of Quantitative Description: Digital Media*, 1.
- [Garimella et al., 2017] Garimella, K., De Francisci Morales, G., Gionis, A. e Mathioudakis, M. (2017). Reducing controversy by connecting opposing views. Em *Proceedings of the Tenth ACM International Conference on Web Search and Data Mining*, p. 81–90.
- [Garimella et al., 2018a] Garimella, K., De Francisci Morales, G., Gionis, A. e Mathioudakis, M. (2018a). Political discourse on social media: Echo chambers, gatekeepers, and the price of bipartisanship. Em *Proceedings of the 2018 World Wide Web Conference - WWW '18*, p. 913–922.
- [Garimella et al., 2018b] Garimella, K., Morales, G. D. F., Gionis, A. e Mathioudakis, M. (2018b). Quantifying controversy on social media. *Trans. Soc. Comput.*, 1(1).
- [Garimella e Weber, 2017] Garimella, V. R. K. e Weber, I. (2017). A long-term analysis of polarization on twitter. *Proceedings of the International AAAI Conference on Web and Social Media*, 11(1):528–531.
- [Gausen et al., 2022] Gausen, A., Luk, W. e Guo, C. (2022). Using agent-based modeling to evaluate the impact of algorithmic curation on social media. *ACM Journal of Data and Information Quality (JDIQ)*.
- [Ge et al., 2020] Ge, Y., Zhao, S., Zhou, H., Pei, C., Sun, F., Ou, W. e Zhang, Y. (2020). Understanding echo chambers in e-commerce recommender systems. *Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval*, p. 2261–2270.

- [Gillani et al., 2018] Gillani, N., Yuan, A., Saveski, M., Vosoughi, S. e Roy, D. (2018). Me, my echo chamber, and i: introspection on social media polarization. Em *Proceedings of the 2018 World Wide Web Conference*, p. 823–831.
- [Goyal e Ferrara, 2018] Goyal, P. e Ferrara, E. (2018). Graph embedding techniques, applications, and performance: A survey. *Knowledge-Based Systems*, 151:78–94.
- [Grover e Leskovec, 2016] Grover, A. e Leskovec, J. (2016). node2vec: Scalable feature learning for networks. Em *Proceedings of the 22nd ACM SIGKDD international conference on Knowledge discovery and data mining*, p. 855–864.
- [Guerra et al., 2013] Guerra, P., Meira Jr, W., Cardie, C. e Kleinberg, R. (2013). A measure of polarization on social media networks based on community boundaries. Em *Proceedings of the 7th International Conference on Weblogs and Social Media, ICWSM 2013*, p. 215–224.
- [Jeon et al., 2021] Jeon, Y., Kim, B., Xiong, A., Lee, D. e Han, K. (2021). Chamberbreaker: Mitigating the echo chamber effect and supporting information hygiene through a gamified inoculation system. *Proceedings of the ACM on Human-Computer Interaction*, 5(CSCW2):1–26.
- [Liu e Krishnan, 2021] Liu, R. e Krishnan, A. (2021). Pecanpy: a fast, efficient and parallelized python implementation of node2vec. *Bioinformatics*, 37(19):3377–3379.
- [Meyer-Baese e Schmid, 2014] Meyer-Baese, A. e Schmid, V. (2014). Chapter 2 - feature selection and extraction. Em Meyer-Baese, A. e Schmid, V., editors, *Pattern Recognition and Signal Analysis in Medical Imaging (Second Edition)*, p. 21–69. Academic Press, Oxford, second edition edição.
- [Mikolov et al., 2013] Mikolov, T., Chen, K., Corrado, G. e Dean, J. (2013). Efficient estimation of word representations in vector space. Em *1st International Conference on Learning Representations, ICLR*, p. 1–12.
- [Minici et al., 2022] Minici, M., Cinus, F., Monti, C., Bonchi, F. e Manco, G. (2022). Cascade-based echo chamber detection. *arXiv preprint arXiv:2208.04620*.
- [Morales et al., 2021] Morales, G. D. F., Monti, C. e Starnini, M. (2021). No echo in the chambers of political interactions on reddit. *Scientific reports*, 11(1):1–12.
- [Morini et al., 2021] Morini, V., Pollacci, L. e Rossetti, G. (2021). Toward a standard approach for echo chamber detection: Reddit case study. *Applied Sciences*, 11(12).
- [Munson et al., 2013] Munson, S., Lee, S. e Resnick, P. (2013). Encouraging reading of diverse political viewpoints with a browser widget. Em *Proceedings of The International AAAI Conference on Web and Social Media*, volume 7, p. 419–428.
- [Nguyen, 2020] Nguyen, C. T. (2020). Echo chambers and epistemic bubbles. *Episteme*, 17(2):141–161.

- [Ou et al., 2016] Ou, M., Cui, P., Pei, J., Zhang, Z. e Zhu, W. (2016). Asymmetric transitivity preserving graph embedding. Em *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, p. 1105–1114.
- [Page et al., 1999] Page, L., Brin, S., Motwani, R. e Winograd, T. (1999). The pagerank citation ranking: Bringing order to the web. Relatório técnico, Stanford InfoLab.
- [Perozzi et al., 2014] Perozzi, B., Al-Rfou, R. e Skiena, S. (2014). Deepwalk: Online learning of social representations. Em *Proceedings of the 20th ACM SIGKDD international conference on Knowledge discovery and data mining*, p. 701–710.
- [Pons e Latapy, 2005] Pons, P. e Latapy, M. (2005). Computing communities in large networks using random walks. Em *International symposium on computer and information sciences*, p. 284–293. Springer.
- [Rossetti e Cazabet, 2018] Rossetti, G. e Cazabet, R. (2018). Community discovery in dynamic networks: A survey. *ACM Comput. Surv.*, 51(2).
- [Rosvall et al., 2009] Rosvall, M., Axelsson, D. e Bergstrom, C. T. (2009). The map equation. *The European Physical Journal Special Topics*, 178(1):13–23.
- [Roweis e Saul, 2000] Roweis, S. T. e Saul, L. K. (2000). Nonlinear dimensionality reduction by locally linear embedding. *science*, 290(5500):2323–2326.
- [Sasahara et al., 2021] Sasahara, K., Chen, W., Peng, H., Ciampaglia, G. L., Flammini, A. e Menczer, F. (2021). Social influence and unfollowing accelerate the emergence of echo chambers. *Journal of Computational Social Science*, 4(1):381–402.
- [Sîrbu et al., 2019] Sîrbu, A., Pedreschi, D., Giannotti, F. e Kertész, J. (2019). Algorithmic bias amplifies opinion fragmentation and polarization: A bounded confidence model. *PloS one*, 14(3):e0213246.
- [Tang et al., 2015] Tang, J., Qu, M., Wang, M., Zhang, M., Yan, J. e Mei, Q. (2015). Line: Large-scale information network embedding. Em *Proceedings of the 24th international conference on world wide web*, p. 1067–1077.
- [Terren e Borge-Bravo, 2021] Terren, L. e Borge-Bravo, R. (2021). Echo chambers on social media: a systematic review of the literature. *Review of Communication Research*, 9:99–118.
- [Tokita et al., 2021] Tokita, C. K., Guess, A. M. e Tarnita, C. E. (2021). Polarized information ecosystems can reorganize social networks via information cascades. *Proceedings of the National Academy of Sciences*, 118(50):e2102147118.
- [Törnberg, 2018] Törnberg, P. (2018). Echo chambers and viral misinformation: Modeling fake news as complex contagion. *PLoS one*, 13(9):e0203958.
- [Villa et al., 2021] Villa, G., Pasi, G. e Viviani, M. (2021). Echo chamber detection and analysis. *Social Network Analysis and Mining*, 11(1):1–17.

- [Wandelt et al., 2020] Wandelt, S., Shi, X. e Sun, X. (2020). Complex network metrics: Can deep learning keep up with tailor-made reference algorithms? *IEEE Access*, 8:68114–68123.
- [Wang et al., 2016] Wang, D., Cui, P. e Zhu, W. (2016). Structural deep network embedding. Em *Proceedings of the 22nd ACM SIGKDD international conference on Knowledge discovery and data mining*, p. 1225–1234.
- [Welling e Kipf, 2016] Welling, M. e Kipf, T. N. (2016). Semi-supervised classification with graph convolutional networks. Em *J. International Conference on Learning Representations (ICLR 2017)*.
- [Williams et al., 2015] Williams, H. T., McMurray, J. R., Kurz, T. e Lambert, F. H. (2015). Network analysis reveals open forums and echo chambers in social media discussions of climate change. *Global environmental change*, 32:126–138.
- [Xu, 2021] Xu, M. (2021). Understanding graph embedding methods and their applications. *SIAM Review*, 63(4):825–853.
- [Yang et al., 2016] Yang, Z., Algesheimer, R. e Tessone, C. J. (2016). A comparative analysis of community detection algorithms on artificial networks. *Scientific reports*, 6(1):1–18.
- [Yue et al., 2020] Yue, X., Wang, Z., Huang, J., Parthasarathy, S., Moosavinasab, S., Huang, Y., Lin, S. M., Zhang, W., Zhang, P. e Sun, H. (2020). Graph embedding on biomedical networks: methods, applications and evaluations. *Bioinformatics*, 36(4):1241–1251.
- [Zannettou et al., 2018] Zannettou, S., Bradlyn, B., De Cristofaro, E., Kwak, H., Sirivianos, M., Stringini, G. e Blackburn, J. (2018). What is gab: A bastion of free speech or an alt-right echo chamber. Em *Companion Proceedings of the The Web Conference 2018*, p. 1007–1014.
- [Zollo et al., 2017] Zollo, F., Bessi, A., Del Vicario, M., Scala, A., Caldarelli, G., Shekhtman, L., Havlin, S. e Quattrociocchi, W. (2017). Debunking in a world of tribes. *PLoS one*, 12(7):e0181821.