

# ECO-SA: Estratégia de Contenção Otimizada da Propagação em Câmaras de Eco utilizando *Simulated Annealing*

Nicollas R. de Oliveira<sup>1</sup>, Dianne S. V. de Medeiros<sup>1</sup>, Diogo M. F. Mattos<sup>1</sup>

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

**Abstract.** *The social phenomenon of echo chambers is a serious threat to the cybersecurity in social networks, as they foster environments conducive to hate speech and the spread of fake news. Members of an echo chamber tend to ignore attempts to refute the unilateral ideas constantly disseminated within it. In this paper, we propose an optimized containment strategy for the spread of information in echo chambers based on Simulated Annealing (ECO-SA). The proposal identifies critical nodes in graphs, which, when blocked, significantly reduce information diffusion. Simulations on 15 samples of echo chambers, applied to an information diffusion model under different scenarios, show that blocking the strategic nodes identified by ECO-SA reduced the spread to only 45% of the nodes in the network, while the competing method restricts the spread to at least 65% of the nodes.*

**Resumo.** *O fenômeno social das câmaras de eco (echo chamber) é uma grave ameaça à cibersegurança em redes sociais, já que fomentam ambientes propícios ao discurso de ódio e à propagação de notícias falsas. Os membros de uma câmara de eco tendem a ignorar tentativas de refutar as ideias unilaterais constantemente difundidas em seu interior. Este artigo propõe uma estratégia de contenção otimizada da propagação de informação em câmaras de eco baseada no Simulated Annealing (ECO-SA). A proposta identifica nós críticos em grafos, que, quando bloqueados, reduzem significativamente a difusão de informações. Simulações em 15 amostras de câmaras de eco, aplicadas a um modelo de difusão de informação sob diferentes cenários, que o bloqueio dos nós estratégicos identificados pela ECO-SA reduziu a disseminação a somente 45% dos nós na rede, enquanto que o método concorrente restringe a disseminação a no mínimo 65% dos nós.*

## 1. Introdução

A facilidade de acesso pervasivo e ubíquo às redes sociais tornou plataformas *online* como *Facebook* e *X* (ex-*Twitter*) importantes meios de interação e comunicação pública, sendo a principal fonte de informação para 74% dos brasileiros [Newman et al., 2024]. Apesar de hospedarem tanto conteúdos úteis para geração de conhecimento, quanto para o entretenimento, é latente a vocação das redes sociais para fomentar e repercutir conteúdos focados no discurso de ódio e em notícias falsas (*fake news*) [de Oliveira et al., 2020]. Tradicionalmente o processo de seleção de

---

Este trabalho foi realizado com recursos do CNPq, CAPES, FAPERJ, RNP (Programa OpenRAN@Brasil, Processo MCTI N° - A01245.014203/2021-14, e Programa de bolsa de Incentivo à Pesquisa), Prefeitura de Niterói/FEC/UFF (Edital PDPA 2020) e INCT ICONIOT.

informação era mediado por jornalistas ou editores. Atualmente, com as mídias sociais, essa mediação passou a ser exercida por todos os usuários. A 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 de “viés de confirmação”. Tal fenômeno expressa a tendência dos usuários de absorverem e compartilharem informações que se aderem ao seu sistema de crenças, mesmo que essas informações sejam inverídicas. Igualmente recorrente nas redes sociais, a câmara de eco (*echo chamber*) é um fenômeno social relacionado à tendência dos usuários de interagirem e ingressarem em grupos homogêneos com ideias semelhantes às suas [Cota et al., 2019, Zollo et al., 2017].

Implicitamente, o fenômeno das câmaras de eco envolve mecanismos que alienam os membros da comunidade, impedindo o acesso a fontes externas de informação epistêmica. Assim, as câmaras de eco funcionam sistematicamente para formar padrões ideológicos disfuncionais que bloqueiam buscas informativas além da comunidade intelectual e desacreditam ativamente informações externas. Como consequência, ocorre um desequilíbrio epistêmico, ou seja, uma distorção e limitação do acesso a informações diversas. Logo, em vez de apenas omitir pontos de vista contrários, esse desequilíbrio gera uma desconfiança ideológica preventiva, confinando os indivíduos dentro das câmaras de eco [Donkers e Ziegler, 2021].

Este artigo propõe a ECO-SA, uma Estratégia de Contenção Otimizada da propagação de informação em câmaras de eco baseada em arrefecimento simulado (*Simulated Annealing*). A estratégia visa encontrar pontos críticos na estrutura das câmaras de eco, reduzindo o nível de propagação de informações aos integrantes da câmara e, consequentemente, desarticulando o ciclo disseminatório. Assim, utiliza-se a metaheurística SA no problema de minimização da propagação para identificar um conjunto de nós específicos em grafos que, quando bloqueados, reduzem drasticamente a contaminação nominal, ou seja, a quantidade total de nós afetados na propagação da informação. A proposta simula a dinâmica de propagação da desinformação dentro de 15 amostras de câmaras de eco reais, aplicadas a modelos de difusão probabilísticos.

Diferentemente de abordagens preventivas, tais como ChamberBreaker [Jeon et al., 2021], Check-my-echo [Bail et al., 2018], StarryThoughts [Kim et al., 2021] e HearHere [Jeon et al., 2024], que focam na preservação de ambientes virtuais plurais ideologicamente, a proposta concentra-se na neutralização estratégica do processo de disseminação de informação em câmaras de eco já formadas. Adicionalmente, a proposta contrasta-se com abordagens anteriores de contenção de desinformação, sendo mais disruptiva por aplicar uma abordagem de busca otimizada. O impacto da proposta relaciona-se à sua capacidade de encontrar um conjunto ótimo e não trivial de nós em uma rede de usuários, o que resulta em um melhor desempenho em comparação com os trabalhos que focam a escolha de nós críticos de acordo com métricas de grafos.

O restante do artigo está organizado da seguinte forma. A Seção 2 introduz o fenômeno das câmaras de eco e a sua importância para a cibersegurança. A Seção 3 explica o processo de estruturação e modelagem das câmaras de eco. A Seção 4 aborda os principais trabalhos relacionados. A Seção 5 detalha a estratégia proposta para mitigação dos efeitos das câmaras de eco. A Seção 6 discute os resultados obtidos e a Seção 7 conclui o artigo.

## 2. Efeitos das Câmaras de Eco

A interação entre usuários dentro das câmaras de eco é marcada pela disseminação de conteúdos enviesados e pela blindagem a tentativas de refutação por opiniões externas. Além disso, devido à natural baixa capacidade humana de distinguir entre notícias verdadeiras e falsas [Shu et al., 2017], as câmaras de eco propiciam a criação e divulgação de notícias falsas. Esses fatores degradam a cibersegurança em redes sociais e geram atritos em diversos campos da sociedade.

A relação de simbiose existente entre redes sociais e eventos ou situações cotidianas impacta diretamente a cibersegurança, permitindo que qualquer indivíduo externalize suas opiniões, crenças e posicionamentos ideológicos através de postagens em seus perfis. A ausência da mediação de profissionais relacionados à divulgação de notícias aliada à liberdade e à facilidade de divulgação de informações nas redes sociais por quaisquer usuários reforça a formação das câmaras de eco [de Oliveira et al., 2021]. Dessa forma, é fundamental desenvolver soluções capazes de detectar e caracterizar câmaras de eco em torno das repercussões de eventos externos às redes sociais. Atrelado ao desafio da caracterização está a dificuldade de fazê-la dinamicamente, acompanhando a velocidade natural de geração e o volume de dados relacionados a eventos reais que potencializam a polaridade de opiniões. Uma maneira de satisfazer esse imediatismo, sem recorrer a técnicas possivelmente mais demoradas e complexas de processamento de linguagem natural e aprendizado de máquina, é através do processamento das palavras-chave indexadoras das mensagens, como as *hashtags* utilizadas nos postagens *online*.

Além dos desafios de monitoramento, detecção e caracterização de câmaras de eco, um terceiro desafio emergente envolve a mitigação de sua expansão e redução de seus efeitos tanto dentro quanto fora da redoma de usuários. Recentemente, o tratamento dessa questão advém de abordagens passivas que visam principalmente o caráter preventivo, buscando a redução da influência de conteúdo tendencioso em usuários por meio da exposição a uma diversidade de perspectivas informacionais. Iniciativas de contenção variam desde abordagens de treinamento baseadas na gamificação, como o ChamberBreaker [Jeon et al., 2021], até ferramentas de detecção de enviesamento de perfis, como o Check-my-echo [Bail et al., 2018], e sistemas de análise e consumo de informações multi-ideológicas, como o StarryThoughts e o HearHere [Kim et al., 2021, Jeon et al., 2024]. No entanto, a falta de uma metodologia ativa de atuação para remover usuários membros de câmaras de eco torna a questão um desafio em aberto tanto no âmbito psicológico quanto computacional. Motivada por ações judiciais<sup>1</sup> ou tomada de decisão voluntária de gestores de redes sociais<sup>2</sup>, a solução de combate mais incisiva consiste no bloqueio de contas ou perfis de usuários específicos. Essa prática de regulação visa dismantlar o ciclo de disseminação em estruturas extremamente polarizadas, como as câmaras de eco. Na prática, a seleção de tais contas é normalmente fundamentada na análise do histórico de postagens de perfis em busca dos chamados disseminadores primários, ou seja, aqueles usuários responsáveis pela criação ou compartilhamento inicial em massa de conteúdo falso na rede.

O isolamento de usuários em câmaras de eco facilita a disseminação de

---

<sup>1</sup>Disponível em: <https://www.nbcnews.com/news/world/brazil-supreme-court-justice-orders-elon-musk-investigation-fake-news-rcna146799>.

<sup>2</sup>Disponível em: <https://www.reuters.com/article/idUSKBN2BE17T/>.

desinformação e a manipulação de opiniões, sendo um desafio para a cibersegurança. A polarização intensificada promove a propagação de informações falsas e aumenta a vulnerabilidade dos usuários a ataques de *phishing* e engenharia social. Além disso, redes formadas a partir da divulgação de *malware* em câmaras podem ser usadas para atividades maliciosas, como ataques DDoS e criação de *botnets*, ameaçando a integridade das infraestruturas digitais [Lee et al., 2023]. Mitigar os efeitos das câmaras de eco promove um ambiente de redes sociais mais saudável e fortalece a cibersegurança global.

### 3. Estruturação e Modelagem de Câmaras de Eco

O problema abstrato de reduzir o compartilhamento de informações inverídicas em câmaras de eco em redes sociais parte da representação do fenômeno segundo uma perspectiva topológica. Diante das suas características estruturais, uma câmara de eco pode ser representada como uma comunidade 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 [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 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 a 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. Existem três modelos principais para representação de redes temporais [Xu, 2021], sendo eles: (i) 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, e  $t$  é o carimbo de tempo do contato; (ii) grafo de intervalo, redes que registram a duração dos períodos de atividade da uma aresta  $e$  através um conjunto de intervalos  $T_e = (t_1, t'_1) \dots (t_n, t'_n)$ ; e (iii) séries de instantâneos, rede segmentada em um conjunto de janelas de tempo sequenciais (*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, a análise desses modelos é mais complexa e depende da aplicação de novas metodologias e algoritmos. A rede temporal representada por uma série de instantâneos 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 de séries de instantâneos é a indeterminação quanto ao tamanho ótimo do intervalo de tempo usado para analisar o grafo. 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].

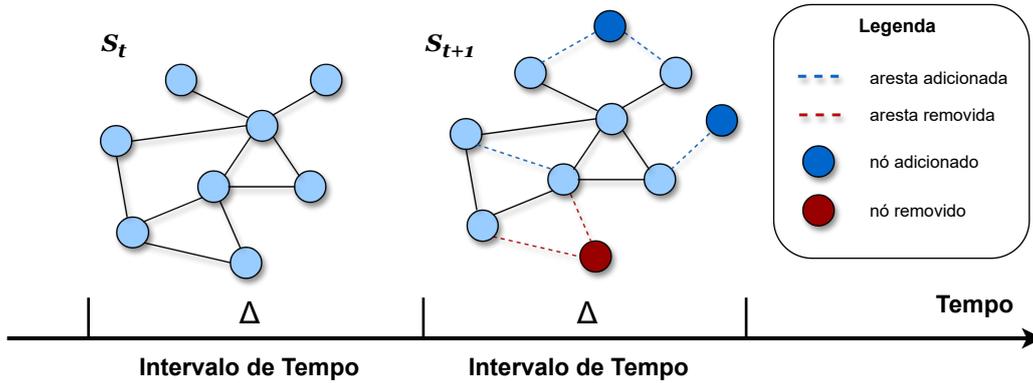


Figura 1. Representação de grafos temporais baseada em séries de instantâneos. A evolução de um grafo dinâmico em tempo discreto  $G$  é modelada como uma série de instantâneos discretos em diferentes intervalos de tempo ( $\Delta$ ), i.e.,  $G = \{S_1, S_2, \dots, S_T\}$ , que contém  $T$  instantâneos estáticos. A modelagem de uma câmara de eco segundo esta representação discreta permite que modificações na sua estrutura, como inclusão ou remoção de nós e arestas, sejam analisadas entre *snapshots* consecutivos.

Devido à dificuldade de investigar câmaras de eco em cenários reais e de maneira contínua e integrada ao fluxo de interações entre seus membros nas redes sociais, alguns trabalhos empregam modelos estatísticos para simular o processo de disseminação de informações e determinar a influência de um conjunto inicial de nós propagadores. Embora detenham critérios de propagação particulares, os modelos podem ser agrupados em três categorias [Zareie e Sakellariou, 2021]: (i) Modelos Epidêmicos, aplicáveis em contextos de “contágio social”, onde as pessoas estão tomando decisões para adotar uma nova ideia ou inovação; (ii) Modelos de Dinâmicas de Opiniões, capazes de lidar com as oscilações dos valores de parâmetros, simulando a mutabilidade das opiniões de cada usuário; e (iii) Modelos de Redes Dinâmicas, adaptados para lidar com a evolução temporal de grafos baseados em instantâneos (*snapshots*) discretos. Apesar da pluralidade de modelos de difusão existentes na literatura, apenas um subconjunto deles é efetivamente aplicável para investigar as câmaras de eco e a difusão de informações e opiniões dentro delas. Essa limitação decorre tanto do modelo possuir uma lógica de funcionamento incoerente com o fenômeno, quanto da obrigatoriedade do uso de parâmetros nativos incompatíveis.

Dentre os modelos alinhados ao cenário de difusão observado em câmaras de eco, destaca-se o modelo *Profile*. Proposto por Milli *et al.* [Milli et al., 2018], este modelo epidêmico considera que cada usuário na rede, representado como um nó, possui uma resistência individual à adoção da informação. Esta resistência interna é o único fator que influencia a mudança de estado de cada usuário durante a propagação, sendo definida entre  $[0, 1]$  pelo parâmetro perfil do usuário ( $Pf$ ). Valores próximos ao limite superior (1) implicam alta resistência interna, enquanto valores próximos ao limite inferior (0) indicam baixa resistência interna à adesão de informações propagadas por terceiros. Opcionalmente, o modelo permite que a mudança de estado ocorra de maneira espontânea, ou seja, independentemente da existência de vizinhos ativos. A probabilidade da ativação exógena é controlada pelo parâmetro  $p_s$ , definido entre  $[0, 1]$ . O limite inferior indica uma probabilidade nula de adotantes espontâneos, enquanto o limite superior indica que todos os nós são adotantes espontâneos. Neste modelo, os nós da rede podem assumir três

estados possíveis — ativo, inativo ou bloqueado — que representam diferentes níveis de adoção da informação. Na prática, a definição dos nós ativos e bloqueados pode ser feita de maneira declarativa ou aleatória.

O processo de difusão do modelo *Profile* pode ser sumarizado em cinco etapas: (1) Escolha do conjunto de nós ativos, ou seja, as fontes de propagação, e o conjunto de nós bloqueados; (2) Varredura e identificação do subconjunto de nós inativos contendo vizinhos ativos; (3) Ativação de cada nó do subconjunto caso seu perfil ( $P_{fl}$ ) seja menor que uma probabilidade gerada aleatoriamente. Tentativas falhas de ativação resultam na alteração do estado inativo para bloqueado; (4) Caso  $p_s > 0$ , adotantes espontâneos podem surgir a qualquer momento da propagação, independente do perfil; e (5) Repetição das três etapas anteriores até alcançar o número máximo de iterações estabelecido.

#### 4. Trabalhos Relacionados

Embora permeie diversas finalidades, como controle epidemiológico, gestão de tráfego, gestão de abastecimento hídrico ou marketing viral, a incorporação de estratégias de mitigação da propagação de fluxos em grafos mostra-se eficaz na redução da disseminação de desinformação [Zareie e Sakellariou, 2021]. A prevalência do compartilhamento de informações inverídicas entre integrantes de câmaras de eco torna essas estratégias uma oportunidade para atenuar esse fenômeno. Ao focar trabalhos relacionados à mitigação da propagação de informação, pode-se distingui-los em dois grupos, dependendo do parâmetro modificado na estrutura do grafo analisado.

As **estratégias baseadas no bloqueio de nós** são também conhecidas como métodos de imunização de nós. Essa classe de estratégias de bloqueio baseia-se na identificação e remoção de um conjunto de nós críticos de um grafo antes do início do processo de propagação. Tais estratégias são consideradas mais disruptiva dado que a remoção de um nó implica a remoção de todas as suas arestas convergente ou divergentes. Dentro deste escopo, Holme *et al.* propõem a identificação de nós-chave cuja remoção aumenta o comprimento geodésico médio inverso, ou seja, a distância média entre pares de nós no grafo [Holme et al., 2002]. O impacto da remoção de nós com alto grau e alta intermediação é avaliado considerando modelos de rede com propriedades estruturais e comportamentais distintas. Embora diminua a propagação de desinformação de maneira diversa dependendo da rede, a alta intermediação mostrou-se a solução testada mais eficiente para escolha dos nós bloqueados. Diferentemente, Dey e Roy [Dey e Roy, 2017] mostram que as maiores diminuições na propagação de informações na rede são alcançadas mediante a adoção de nós com alta centralidade de proximidade como nós bloqueados. Essa conclusão é fundamentada pela modelagem da propagação segundo o algoritmo de passeio aleatório, ao bloquear os nós mais centrais em termos de diversas centralidades. Paralelamente, Pham *et al.* desenvolvem um método para encontrar um conjunto de nós a serem removidos, considerando o custo associado a cada nó bloqueado [Pham et al., 2018]. O intuito é garantir que o custo total não exceda um limite e que o número máximo de saltos na propagação seja limitado. A partir da construção de uma subárvore a partir do nó inicial, calcula-se a influência de cada nó nessa subárvore usando busca em profundidade. Ao aplicar programação dinâmica, garante-se uma solução quase ótima composta pelos nós com maior impacto na disseminação da desinformação.

As **estratégias baseadas no bloqueio de arestas** identificam e removem um conjunto específico de arestas de um grafo antes do início do processo de propagação. Apesar de serem menos disruptivas e permitirem uma canalização mais refinada do fluxo de informação, métodos dessa classe podem ser mais computacionalmente custosos devido à tradicional desproporção entre o número de nós e arestas. Dentre essas estratégias, Kimura *et al.* introduzem um método capaz de estimar e minimizar a contaminação em um grafo segundo três principais etapas [Kimura et al., 2009]. Na primeira etapa, é executada a percolação de ligação, um processo repetido várias vezes no grafo original, resultando em uma série de  $M$  variações do grafo original com arestas aleatoriamente removidas. Na segunda etapa, calcula-se a influência de cada nó com base nas conexões presentes nos grafos resultantes. Essa influência é uma medida da extensão em que um nó afeta a propagação da contaminação no grafo. Na terceira etapa, um algoritmo ganancioso é aplicado para identificar as  $k$  arestas que minimizam a contaminação média ou máxima no grafo, selecionando-as de acordo com o objetivo definido. Khalil *et al.* têm como objetivo bloquear um conjunto de  $k$  arestas para reduzir a suscetibilidade à propagação na rede, definida como a soma das influências de todos os nós [Khalil et al., 2013]. Sob o modelo de difusão *Linear Threshold*, demonstra-se que o problema formulado é submodular e monotônico. Para resolvê-lo, propõe-se um algoritmo ganancioso que utiliza o método de arestas ativas, garantindo uma solução próxima da ótima. Em outra perspectiva, Tong *et al.* visam identificar um conjunto de arestas cuja remoção minimize os autovalores da matriz de adjacência da rede, utilizados como medida de suscetibilidade à propagação [Tong et al., 2012]. Com base nos autovetores associados a esses autovalores, calcula-se uma pontuação para cada aresta, e as  $k$  arestas com as maiores pontuações são selecionadas como solução.

Perante os trabalhos publicados na literatura que objetivam reduzir a propagação de informação em redes sociais, a proposta diferencia-se em três aspectos. (i) O primeiro aspecto reside na aplicabilidade específica da proposta. Dentro do escopo bibliográfico pesquisado, não foram encontrados trabalhos prévios que se dediquem especificamente à minimização da propagação de informação dentro de câmaras de eco, tampouco utilizando uma estratégia otimizada baseada no bloqueio de nós críticos. (ii) O segundo diferencial diz respeito à eficácia das soluções encontradas pela estratégia proposta, uma vez que é baseada no *Simulated Annealing*. (iii) O terceiro aspecto relaciona-se à abrangência das avaliações, uma vez que as modelagens são conduzidas considerando 15 amostras de câmaras de eco explorados em cenários diversos. Além dessa avaliação intrametodológica, a proposta é comparada com outras estratégias de contenção de propagação, sob as mesmas condições iniciais. Independentemente dos cenários modelados e dos trabalhos comparados, a solução encontrada pela estratégia proposta resulta em um maior impacto na redução da propagação de informação na rede.

## 5. Estratégia de Bloqueio Otimizada

Este artigo visa reduzir a disseminação excessiva de conteúdos em redes sociais, especialmente em estruturas conhecidas como câmaras de eco. Para isso, propõe-se a **ECO-SA**, uma **Estratégia de Contenção Otimizada** da propagação em câmaras de eco baseada no *Simulated Annealing*. Essa estratégia é uma variação da meta-heurística *Simulated Annealing* (SA), adaptada para otimizar a busca por um subconjunto estratégico de nós em um grafo, que quando bloqueados minimizam a propagação de conteúdos

dentro da rede. Assim, o ECO-SA combina a exploração aleatória de soluções com um mecanismo de aceitação probabilística para encontrar uma solução ótima.

A meta-heurística SA foi originalmente desenvolvida com o propósito de encontrar o mínimo global de uma função, baseando-se nos princípios da mecânica estatística [Kirkpatrick et al., 1983]. Esta busca parte de uma solução inicial gerada aleatoriamente e possui uma convergência comprovadamente assegurada para uma solução global ótima  $\xi$ . Em cada iteração, a meta-heurística produz uma solução aleatória  $\xi'$  na vizinhança da melhor solução atualmente conhecida. O desempenho da solução candidata  $\xi$  é avaliado segundo uma função de perda  $f(\xi)$ , que no contexto da mitigação da propagação da informação é a função de perda global. Soluções que minimizam a função de perda são sempre aceitas, enquanto que as demais podem ser aceitas probabilisticamente dependendo do parâmetro de temperatura simulada  $T$  atual e da degradação  $\Delta E$  da função de perda. Expresso na Equação 1, o  $\Delta E$  quantifica a diferença entre o valor da função de perda para a solução atual  $f(\xi)$  e para a solução candidata  $f(\xi')$ .

$$\Delta E = f(\xi') - f(\xi) \quad (1) \quad P(\Delta E, T) = e^{-\Delta E/T} \quad (2)$$

A função de probabilidade dada pela Equação 2 mede a probabilidade de transição da solução atual  $\xi$  para uma solução candidata pior  $\xi'$ , seguindo a distribuição de Boltzmann. Uma temperatura mais baixa reduz a probabilidade de aceitar uma solução pior, favorecendo a melhor solução. O valor negativo da razão  $\Delta E$  e  $T$  na função exponencial reforça essa diminuição de probabilidade. O parâmetro  $\alpha$ , definido no intervalo  $]0, 1[$ , representa a redução gradual da temperatura simulada [Neto et al., 2022].

Computacionalmente, a estratégia ECO-SA pode ser codificada segundo o Algoritmo 1. Dentre os parâmetros de entrada admitidos pelo algoritmo estão: o grafo analisado ( $\mathcal{G}$ ), o conjunto de nós propagadores iniciais ( $V_0$ ), a temperatura inicial ( $T_0$ ), a temperatura mínima ( $T_{min}$ ), a taxa de resfriamento ( $\alpha$ ) e uma solução inicial ( $S_{inicial}$ ). Esta solução é modelada como o conjunto composto por  $N$  nós bloqueados escolhidos aleatoriamente. Sendo uma estratégia insensível à fonte, a ECO-SA sempre exclui os nós iniciais desse conjunto de bloqueio.

A inicialização do algoritmo inclui a definição da temperatura atual ( $T$ ) como sendo igual a  $T_0$  e a determinação do conjunto de nós disponíveis para bloqueio ( $V_D$ ), dado pela diferença entre o conjunto total de nós do grafo e o conjunto de nós iniciais (linhas 1 e 2). O impacto mitigatório da solução inicial no grafo analisado é modelado segundo a função objetivo `PropagationImpact` (linha 4). Internamente, a função implementa um modelo de difusão de informação iniciado nos nós iniciais e bloqueando os nós definidos pela solução inicial. Assim, o custo relacionado à solução inicial é retornado na forma de nível de propagação nominal, ou seja, na quantidade de nós ativados ao término de um número fixo de iterações do modelo. Essa solução inicial é considerada a melhor solução encontrada até o momento, e seu custo é registrado como o melhor custo (linhas 5 e 6). Em seguida, o algoritmo mantém-se em um *loop* principal, enquanto a temperatura atual for maior ou igual à temperatura mínima  $T_{min}$ . Dentro do *loop*, diferentes soluções candidatas são exploradas com o objetivo de encontrar aquela que minimize a propagação. A cada iteração, uma solução candidata ( $S_{candidata}$ ) é obtida modificando a solução atual usando a função `UpdateSolution` (linha 8). Essa função é responsável pela substituição aleatória de um nó presente na solução atual por outro pertencente ao

**Algoritmo 1:** Estratégia Otimizada de Bloqueio de Nós

---

**Entrada:**  $G = (V, E), V_0, T_0, T_{min}, \alpha, S_{inicial}$   
**Saída :**  $S_{melhor}$

- 1  $T \leftarrow T_0$
- 2  $V_D \leftarrow V - V_0$
- 3  $S_{atual} \leftarrow S_{inicial}$
- 4  $C_{atual} \leftarrow \text{PropagationImpact}(G, V_0, S_{atual})$
- 5  $S_{melhor} \leftarrow S_{atual}$
- 6  $C_{melhor} \leftarrow C_{atual}$
- 7 **while**  $T \geq T_{min}$  **do**
- 8  $S_{candidata} \leftarrow \text{UpdateSolution}(V_D, S_{atual})$
- 9  $C_{novo} \leftarrow \text{PropagationImpact}(G, V_0, S_{candidata})$
- 10  $\Delta E \leftarrow C_{novo} - C_{atual}$
- 11  $P = e^{-\Delta E/T}$
- 12 **if**  $\Delta E < 0$  **or**  $\text{norm.cdf}(\text{np.random.normal}(0, 1)) < P$  **then**
- 13  $S_{atual} \leftarrow S_{candidata}$
- 14  $C_{atual} \leftarrow C_{novo}$
- 15 **if**  $C_{atual} < C_{melhor}$  **then**
- 16  $S_{melhor} \leftarrow S_{atual}$
- 17  $C_{melhor} \leftarrow C_{atual}$
- 18 **end**
- 19 **end**
- 20  $T \leftarrow \alpha \cdot T$
- 21 **end**
- 22 **return**  $S_{melhor}$

---

conjunto de nós disponíveis para bloqueio. A solução candidata encontrada tem seu custo calculado usando a função objetivo e comparado com o custo atual (linhas 9 e 10). A partir da variação de energia entre a solução atual e a solução candidata e da temperatura atual, calcula-se a probabilidade  $P$  (linha 11). Quaisquer soluções que derivem em variações negativas são imediatamente aceitas. Contudo, a solução piorante também pode ser aceita, desde que a probabilidade calculada seja maior que a função de distribuição acumulada de uma variável aleatória normal com média igual a 0 e desvio padrão igual a 1 (linha 12). A solução candidata aceita e seus respectivos custos (linhas 13 e 14) atualizam a solução atual e seu custo, respectivamente. Em seguida, verifica-se se o custo atual  $C_{atual}$  é menor do que o custo da melhor solução encontrada até o momento  $C_{melhor}$ . Se isso for verdade, a melhor solução  $S_{melhor}$  e seu custo  $C_{melhor}$  são atualizados com os valores da solução atual e do novo custo, respectivamente. Durante o decorrer do *loop*, a temperatura atual é gradualmente reduzida multiplicando-a pelo fator de resfriamento ( $\alpha$ ), o que controla a probabilidade de aceitar soluções piores (linha 20). Tal procedimento é realizado para prevenir o aprisionamento em ótimos locais subótimos e promover a exploração abrangente do espaço de soluções. Uma vez atingida a condição de parada ( $T < T_{min}$ ), o algoritmo retorna a melhor solução encontrada  $S_{melhor}$ , que representa o conjunto ótimo de nós a serem bloqueados.

## 6. Avaliação da Proposta e Resultados Experimentais

A avaliação da proposta foi conduzida sob duas perspectivas: (i) intrametodológica, contendo um conjunto de experimentos simulando a propagação de informações dentro de câmaras de eco em diferentes redes e cenários de configuração; (ii) intermetodológica, incluindo um conjunto de experimentos comparativos entre o desempenho mitigatório da ECO-SA e de outras abordagens de bloqueio. Em ambas as perspectivas utiliza-se a base de dados apresentada por Morini *et al.* [Morini et al., 2021], composta por câmaras de eco construídas a partir do monitoramento do uso da rede social *Reddit* por usuários americanos. Embora pouco explorado na literatura, o *Reddit* facilita o processo de construção de câmaras de eco, uma vez que a própria plataforma é organizada em comunidades. Os 15 exemplares de câmaras de eco permeiam o debate sobre três questões sociopolíticas: controle de armas, discriminação de minorias e política americana, durante cinco semestres consecutivos. Na prática, cada câmara de eco é representada por um grafo não direcionado e ponderado  $G = (V, E, W)$ , onde cada nó  $v_i$  representa um usuário distinto, cada aresta  $\varepsilon_{i,j}$  representa uma interação entre usuários e o peso  $w_{i,j}$  representa a intensidade dessa interação entre eles. Mediante uma análise manual da inclinação ideológica de cada postagem, os autores classificaram cada nó em um dos três possíveis rótulos: Pro-Trump, Anti-Trump ou Neutro. Detalhes estruturais e estatísticas sobre cada exemplo são expressos na Tabela 1.

**Tabela 1. Características e estatísticas das câmaras de eco analisadas.**

Tópico Debatido	Snapshot	Período	# Nós	# Arestas	Densidade	Diâmetro	Condutância
Controle de Armas	$S_1$	01/17 - 07/17	833	4044	0.006	11	0.444
	$S_2$	07/17 - 01/18	847	3925	0.007	11	0.498
	$S_3$	01/18 - 07/18	1054	3942	0.007	10	0.494
	$S_4$	07/18 - 01/19	985	3478	0.006	10	0.551
	$S_5$	01/19 - 07/19	1046	3601	0.006	10	0.459
Discriminação de Minorias	$S_1$	01/17 - 07/17	1040	3765	0.007	11	0.421
	$S_2$	07/17 - 01/18	1004	3465	0.007	10	0.417
	$S_3$	01/18 - 07/18	1170	3832	0.006	10	0.417
	$S_4$	07/18 - 01/19	1113	3594	0.006	10	0.409
	$S_5$	01/19 - 07/19	1126	3405	0.007	11	0.404
Esfera Política	$S_1$	01/17 - 07/17	917	2525	0.007	10	0.639
	$S_2$	07/17 - 01/18	746	1816	0.006	12	0.561
	$S_3$	01/18 - 07/18	825	2179	0.006	13	0.516
	$S_4$	07/18 - 01/19	775	1787	0.005	11	0.543
	$S_5$	01/19 - 07/19	686	1411	0.012	8	0.558

Vale ressaltar que as simulações foram realizadas em uma máquina virtual com Ubuntu 22.04 LTS, equipado com um processador QEMU Virtual versão 2.5+ 3,2 Ghz, com 4 GB de RAM e 40 GB de armazenamento. Os resultados apresentados são médias de 30 execuções com intervalo de confiança de 95%.

### 6.1. Avaliação Intrametodológica

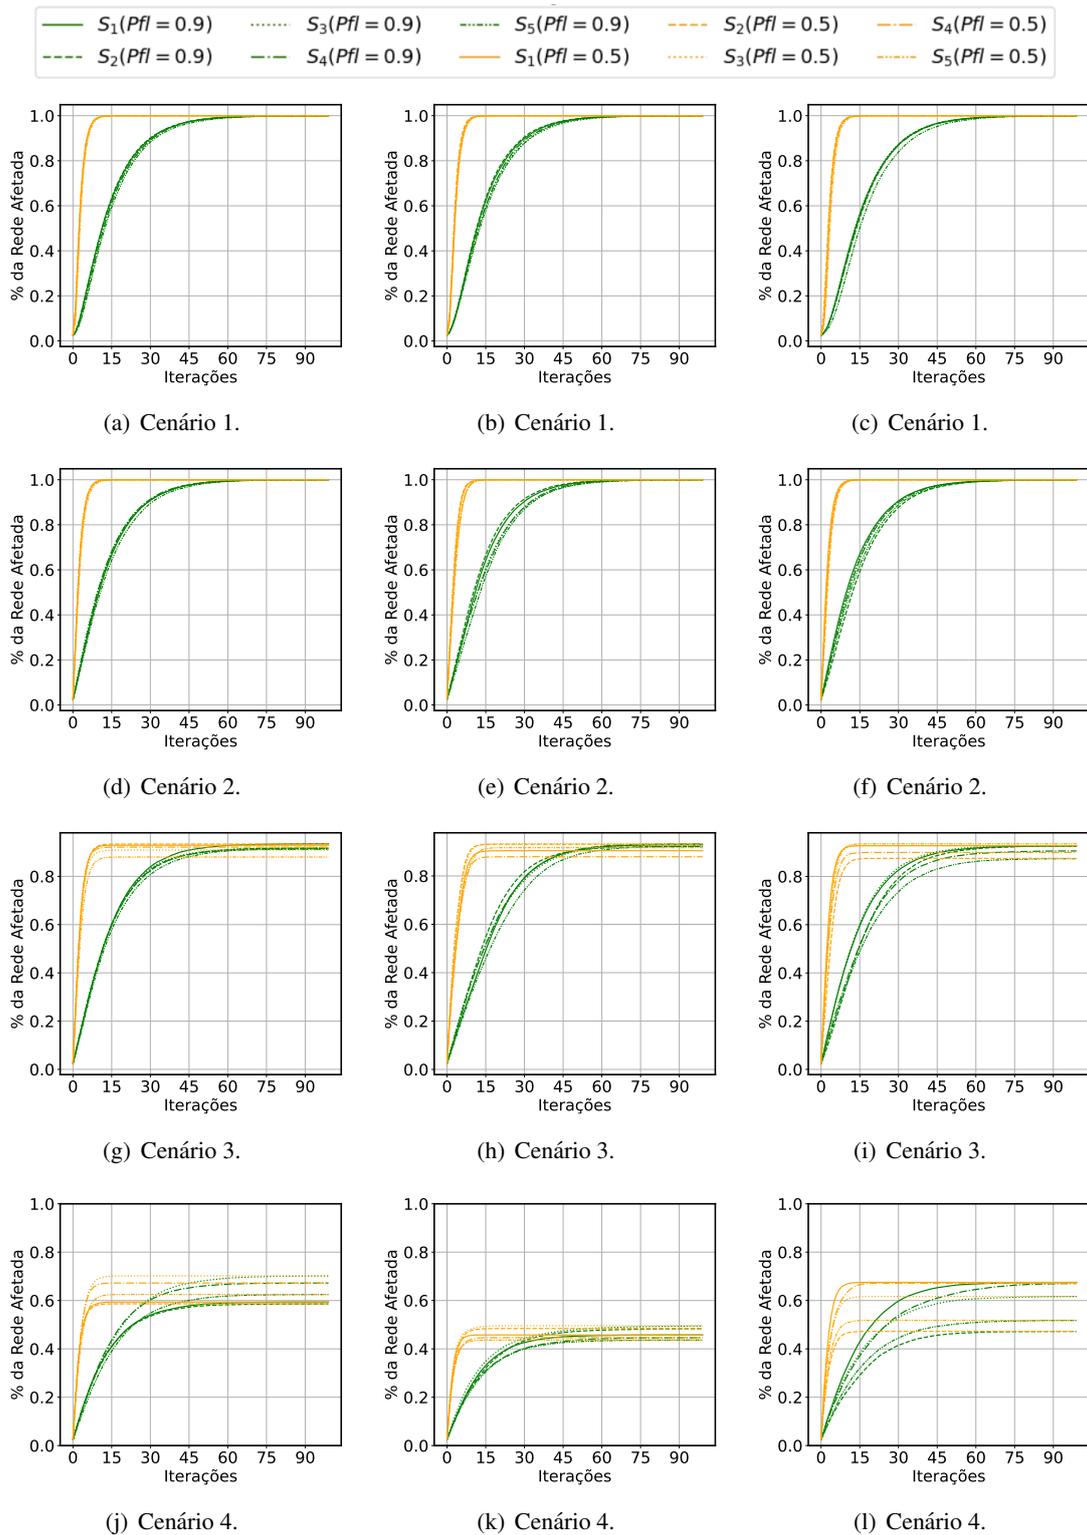
O primeiro conjunto de simulações considera cenários contendo estratégias de mitigação da disseminação de informação em grafos, adotando o modelo *Profile*. Este modelo de difusão de informação admite apenas um *snapshot* por execução, permitindo analisar a propagação de forma individualizada e independente dos demais *snapshots*. Ao variar o critério de escolha dos nós iniciais ( $V_0$ ) e a presença e o critério de escolha dos nós bloqueados ( $V_B$ ), foram originados quatro cenários distintos:

- **Cenário 1.** Propagação iniciada por 2,5% dos nós da rede, escolhidos aleatoriamente ( $V_0^A = 2,5\%$ ) e sem bloqueio de nós.
- **Cenário 2.** Propagação iniciada por 2,5% dos nós mais centrais da rede, escolhidos com base na centralidade de informação ( $V_0^I = 2,5\%$ ) e sem bloqueio de nós.
- **Cenário 3.** Propagação iniciada por 2,5% dos nós mais centrais da rede, escolhidos com base na centralidade de informação ( $V_0^I = 2,5\%$ ), e com bloqueio de 5% dos nós da rede, selecionados aleatoriamente ( $V_B^A = 5\%$ ).
- **Cenário 4.** Propagação iniciada por 2,5% dos nós mais centrais da rede, escolhidos com base na centralidade de informação ( $V_0^I = 2,5\%$ ), e com bloqueio de 5% dos nós da rede, selecionados estrategicamente pelo ECO-SA ( $V_B^S = 5\%$ ).

Cada cenário foi testado em todos os *snapshots* ( $S_1$  a  $S_5$ ) de cada tópico relacionado às câmaras de eco. Além disso, todos os cenários foram avaliados considerando dois perfis de usuários: aqueles com alta resistência à adesão de conteúdos compartilhados por vizinhos e aqueles com média resistência à adesão. Esses perfis foram inseridos no modelo por meio do parâmetro inicial *Profile* ( $Pfl$ ), com valores de 0.9 e 0.5, respectivamente. Os efeitos dos cenários na modelagem computacional da propagação de informações dentro das câmaras de eco são observados nas Figuras 2(a)–(l). Todos os resultados exibem a porcentagem da rede afetada ao longo das 100 iterações do modelo. As curvas referentes a cada *snapshot* representam as médias extraídas após múltiplas execuções, enquanto a área sombreada representa a faixa de confiança.

Analisando as Figuras 2(a)–(c), percebe-se que no Cenário 1 há uma sobreposição de todas as curvas de propagação relativas ao mesmo perfil de usuário, independentemente do tópico analisado. Contudo, é notório e esperado que as curvas relativas ao perfil com média resistência ( $Pfl = 0.5$ ) ascendam mais rapidamente que as do perfil com alta resistência ( $Pfl = 0.9$ ). Vale destacar que as curvas, especialmente as verdes, exibem um leve padrão sigmoidal, demonstrando que a aleatoriedade na escolha dos nós iniciais atrasou a propagação na câmara de eco. No Cenário 2, observa-se um comportamento muito semelhante ao cenário anterior. No entanto, a seleção dos nós iniciais com base na centralidade de informação resultou na perda da característica sigmoidal das curvas. No Cenário 3, percebe-se que a escolha aleatória dos nós bloqueados limita a propagação a, no máximo, 85% do total de nós da rede. Considerando que o percentual máximo de adesão num cenário sem nós bloqueados é de 95%, o impacto desse bloqueio aleatório foi de aproximadamente 10%.

Por fim, as Figuras 2(j)–(l) exibem os efeitos na propagação ao adotar o Cenário 4, onde a seleção do grupo de nós bloqueados é orientada pela estratégia de mitigação proposta. Percebe-se que todas as curvas, independentemente do perfil, foram reduzidas a no máximo 65% da rede. Isto corresponde a uma queda de aproximadamente 30% na porcentagem da rede afetada. Ademais, é perceptível que a inclinação das curvas, sobretudo as verdes, foi suavizada, corroborando a percepção de redução do efeito em cascata na propagação entre os nós. A Figura 2(l) expressa um resultado similar, contudo a redução na propagação foi mais variável, alternando entre 15 a 35% de redução na disseminação dentro de câmaras de eco.



**Figura 2. Disseminação em câmaras de eco pelo modelo *Profile* com e sem estratégias de contenção. As colunas de gráficos, da esquerda para a direita, representam os temas: controle de armas, discriminação de minorias e esfera política, respectivamente.**

## 6.2. Avaliação Intermetodológica

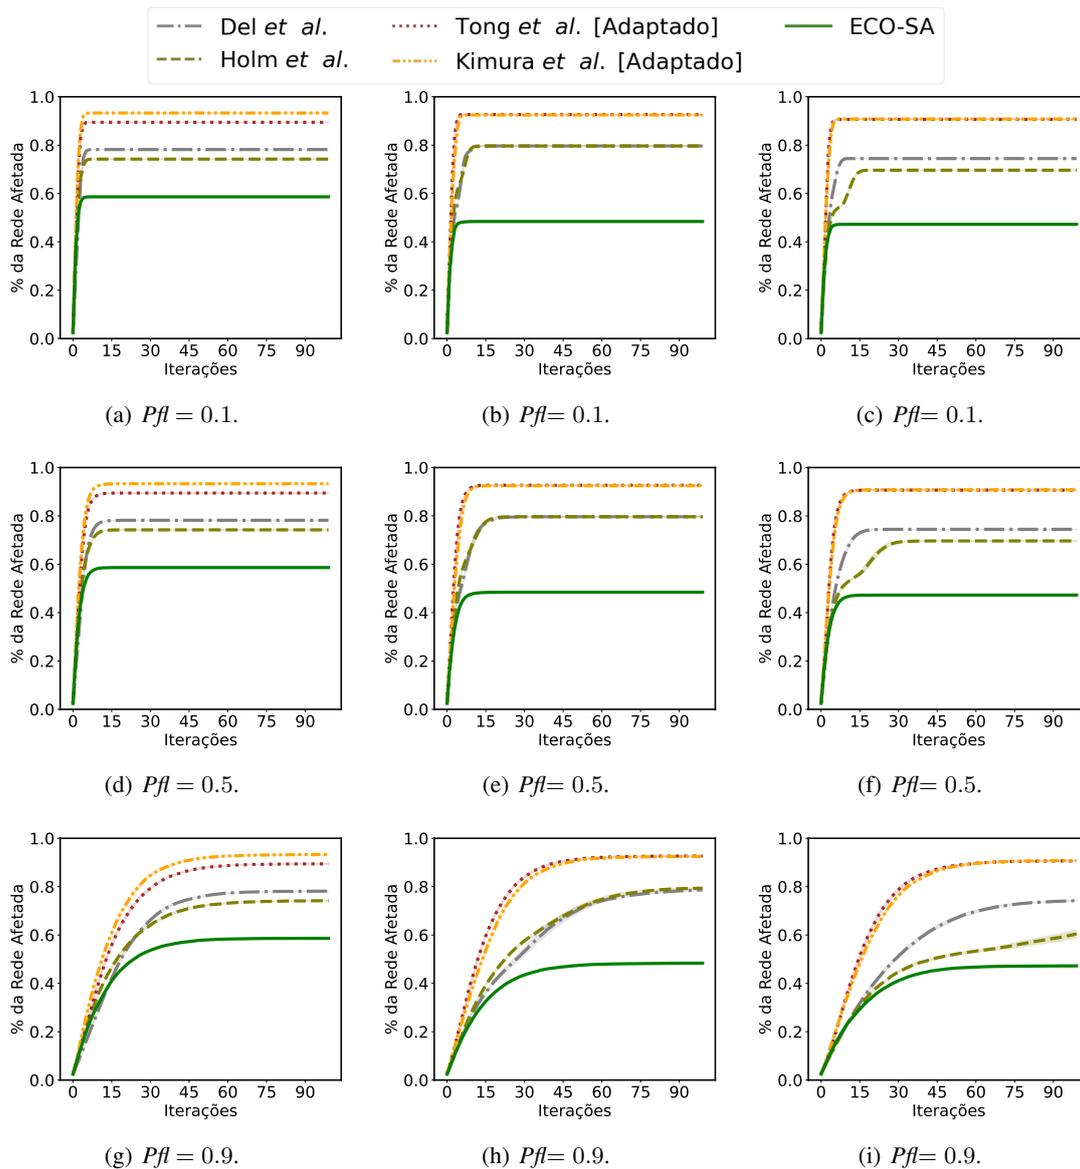
O segundo grupo de simulações atua na avaliação do desempenho do ECO-SA perante trabalhos prévios na tarefa de conter a propagação no interior de câmaras de eco. Diante da ausência de estratégias ou métodos específicos para esse cenário na literatura, optou-se por comparar a proposta com trabalhos dedicados ao controle da difusão de informações em redes sociais. Os trabalhos usados como base comparativa — Holme *et al.* [Holme et al., 2002], Dey *et al.* [Dey e Roy, 2017], Tong *et al.* [Tong et al., 2012] e Kimura *et al.* [Kimura et al., 2009] — propõem estratégias distintas para minimizar a contaminação, seja pelo bloqueio de nós ou de arestas. Para compará-los sob as mesmas perspectivas, os dois últimos foram minimamente adaptados para o cenário de identificação de nós críticos. Em Kimura *et al.*, essa adaptação foi realizada por meio da percolação de nós em vez de arestas. Assim, ao executar o processo de percolação 500 vezes ( $M = 500$ ) e calcular o grau de contaminação pelo pior caso, identifica-se um grupo de nós estratégicos. Em Tong *et al.*, modificou-se o parâmetro analisado, fazendo com que o novo objetivo seja localizar o conjunto de nós do grafo cuja remoção minimize os autovalores da matriz de adjacência da rede.

Adotando o modelo *Profile*, as simulações empregaram o segundo *snapshot* ( $S_2$ ) de cada tema relacionada a câmaras de eco. Cada simulação foi executada sob as mesmas condições iniciais: (i) propagação iniciada por 2,5% dos nós mais centrais da rede, escolhidos com base na centralidade de informação ( $V_0^I = 2,5\%$ ); (ii) com bloqueio de 5% dos nós da rede, selecionados por cada estratégia comparada. O parâmetro *profile* ( $Pfl$ ) foi alternado entre 0.1, 0.5 e 0.9, refletindo perfis de usuários com baixa, média e alta resistência à adesão de conteúdos compartilhados por vizinhos.

A Figura 3 ilustra comparativamente o impacto percentual na propagação modelada pelo modelo *Profile*, utilizando os nós bloqueados derivados de cada estratégia. Cada curva representa a porcentagem acumulada da rede afetada ao longo de 100 iterações do modelo, calculada com base na média de 30 execuções. Independente do perfil ou tópico analisado, constata-se uma superioridade da estratégia otimizada proposta em relação às demais. O maior desempenho na contenção é refletido tanto de maneira evolutiva, estabilizando mais rapidamente a propagação entre nós, quanto nominal, reduzindo drasticamente a porcentagem de nós afetados. Conforme observado nas Figuras 3(a) e 3(f), o bloqueio dos nós estratégicos identificados pela ECO-SA limitou a disseminação a aproximadamente 45% a 60% do total de nós, enquanto que o segundo melhor método restringiu a disseminação a cerca de 65% a 75%, respectivamente.

## 7. Conclusão

Esse artigo propôs a ECO-SA, uma estratégia otimizada para conter a propagação de informação em câmaras de eco, utilizando a meta-heurística *Simulated Annealing*. Tradicionalmente utilizada para resolver problemas complexos, essa meta-heurística combina exploração aleatória e aceitação probabilística para encontrar uma solução ótima. Adaptando-a ao cenário de contenção da difusão de informação em grafos, a ECO-SA visou encontrar o conjunto ótimo de nós críticos em uma câmara de eco que, quando bloqueados, minimizam a contaminação nominal. Experimentos foram conduzidos segundo dois conjuntos de simulações adotando 15 amostras de câmaras de eco aplicadas a um modelos de difusão de informação sob diferentes cenários. No primeiro conjunto de simulações, foi conduzida uma avaliação intrametodológica que compara tanto



**Figura 3.** Comparação das estratégias de contenção da propagação de informação dentro de câmaras de eco utilizando o modelo *Profile*. As colunas de gráficos, da esquerda para a direita, representam os temas: controle de armas, discriminação de minorias e esfera política, respectivamente. Independentemente do cenário testado, constata-se que a ECO-SA supera as demais propostas, limitando a disseminação entre os nós a aproximadamente 45% a 60% do total.

cenários de disseminação submetidos à estratégia de mitigação proposta quanto aqueles sem ela, utilizando o modelo *Profile*. As simulações mediram a porcentagem acumulada de nós afetados e o número mínimo de iterações até a estabilidade, considerando perfis de usuários com resistência média e baixa à adesão de conteúdos compartilhados por vizinhos. O segundo conjunto de simulações focou na avaliação intermetodológica, comparando a ECO-SA com outros métodos de mitigação da propagação de informação em redes. Utilizando as mesmas condições iniciais, demonstrou-se a superioridade da ECO-SA em relação aos demais métodos. Como trabalhos futuros, pretende-se estender as análises de propagação de informação em câmaras de eco, incorporando outras bases de dados e incluindo modelos de disseminação simultânea de múltiplas opiniões.

## Referências

- [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.
- [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.
- [de Oliveira et al., 2020] de Oliveira, N. R., Medeiros, D. S. e Mattos, D. M. (2020). A sensitive stylistic approach to identify fake news on social networking. *IEEE Signal Processing Letters*, 27:1250–1254.
- [de Oliveira et al., 2021] de Oliveira, N. R., Medeiros, D. S. e Mattos, D. M. (2021). 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.
- [Dey e Roy, 2017] Dey, P. e Roy, S. (2017). Centrality based information blocking and influence minimization in online social network. Em *2017 IEEE international conference on advanced networks and telecommunications systems (ANTS)*, p. 1–6. IEEE.
- [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.
- [Holme et al., 2002] Holme, P., Kim, B. J., Yoon, C. N. e Han, S. K. (2002). Attack vulnerability of complex networks. *Physical review E*, 65(5):056109.
- [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.
- [Jeon et al., 2024] Jeon, Y., Kim, J., Park, S., Ko, Y., Ryu, S., Kim, S.-W. e Han, K. (2024). Hearhere: Mitigating echo chambers in news consumption through an ai-based web system. *arXiv preprint arXiv:2402.18222*.
- [Khalil et al., 2013] Khalil, E., Dilkina, B. e Song, L. (2013). Cuttingedge: Influence minimization in networks. Em *Proceedings of Workshop on Frontiers of Network Analysis: Methods, Models, and Applications at NIPS*, p. 1–13.
- [Kim et al., 2021] Kim, H., Kim, H., Jo, K. J. e Kim, J. (2021). Starrythoughts: Facilitating diverse opinion exploration on social issues. *Proceedings of the ACM on Human-Computer Interaction*, 5(CSCW1):1–29.
- [Kimura et al., 2009] Kimura, M., Saito, K. e Motoda, H. (2009). Blocking links to minimize contamination spread in a social network. *ACM Transactions on Knowledge Discovery from Data (TKDD)*, 3(2):1–23.
- [Kirkpatrick et al., 1983] Kirkpatrick, S., Gelatt Jr, C. D. e Vecchi, M. P. (1983). Optimization by simulated annealing. *science*, 220(4598):671–680.

- [Lee et al., 2023] Lee, Y., Ozer, M., Corman, S. R. e Davulcu, H. (2023). Detecting and measuring the polarization effects of adversarial botnets on twitter. Em *Proceedings of the 38th ACM/SIGAPP Symposium on Applied Computing*, p. 1641–1649.
- [Milli et al., 2018] Milli, L., Rossetti, G., Pedreschi, D. e Giannotti, F. (2018). Information diffusion in complex networks: The active/passive conundrum. Em *Complex Networks & Their Applications VI: Proceedings of Complex Networks 2017 (The Sixth International Conference on Complex Networks and Their Applications)*, p. 305–313. Springer.
- [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).
- [Neto et al., 2022] Neto, H. N. C., Dusparic, I., Mattos, D. M. e Fernande, N. C. (2022). Fedsa: Accelerating intrusion detection in collaborative environments with federated simulated annealing. Em *2022 IEEE 8th International Conference on Network Softwarization (NetSoft)*, p. 420–428. IEEE.
- [Newman et al., 2024] Newman, N., Fletcher, R., Schulz, A., Andı, S., Robertson, C. T. e Nielsen, R. K. (2024). Digital news report 2024. Relatório técnico, Reuters Institute for the Study of Journalism.
- [Pham et al., 2018] Pham, C. V., Thai, M. T., Duong, H. V., Bui, B. Q. e Hoang, H. X. (2018). Maximizing misinformation restriction within time and budget constraints. *Journal of Combinatorial Optimization*, 35(4):1202–1240.
- [Rossetti e Cazabet, 2018] Rossetti, G. e Cazabet, R. (2018). Community discovery in dynamic networks: A survey. *ACM Comput. Surv.*, 51(2).
- [Shu et al., 2017] Shu, K., Sliva, A., Wang, S., Tang, J. e Liu, H. (2017). Fake news detection on social media: A data mining perspective. *ACM SIGKDD Explorations Newsletter*, 19(1):22–36.
- [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.
- [Tong et al., 2012] Tong, H., Prakash, B. A., Eliassi-Rad, T., Faloutsos, M. e Faloutsos, C. (2012). Gelling, and melting, large graphs by edge manipulation. Em *Proceedings of the 21st ACM international conference on Information and knowledge management*, p. 245–254.
- [Xu, 2021] Xu, M. (2021). Understanding graph embedding methods and their applications. *SIAM Review*, 63(4):825–853.
- [Zareie e Sakellariou, 2021] Zareie, A. e Sakellariou, R. (2021). Minimizing the spread of misinformation in online social networks: A survey. *Journal of Network and Computer Applications*, 186:103094.
- [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.