

HỌC VIỆN CÔNG NGHỆ BƯU CHÍNH VIỄN THÔNG



NGUYỄN THỊ NGỌC HUYỀN

**TỐI ĐA HÓA ẢNH HƯỞNG TRÊN MẠNG ĐA KÊNH KẾT HỢP GIỮA MÔ
HÌNH SINH VÀ HỌC TĂNG CƯỜNG**

Chuyên ngành: Hệ thống thông tin

Mã số: 8.48.01.04

TÓM TẮT ĐỀ ÁN TỐT NGHIỆP THẠC SĨ

Hà Nội – Năm 2025

Đề án tốt nghiệp được hoàn thành tại:
HỌC VIỆN CÔNG NGHỆ BƯU CHÍNH VIỄN THÔNG

Người hướng dẫn khoa học: PGS. TS. Phạm Văn Cường
(Ghi rõ học hàm, học vị)

Phản biện 1:

Phản biện 2:

Đề án tốt nghiệp sẽ được bảo vệ trước Hội đồng chấm đề án tốt nghiệp thạc sĩ tại Học viện Công nghệ Bưu chính Viễn thông

Vào lúc: giờ ngày tháng năm

Có thể tìm hiểu đề án tốt nghiệp tại:

- Thư viện của Học viện Công nghệ Bưu chính Viễn thông.

MỞ ĐẦU

1. Tính cấp thiết của đề tài

Dữ liệu đồ thị đã tìm thấy nhiều ứng dụng trong các lĩnh vực như mạng xã hội và khai thác dữ liệu [23] [54] [14] [17]. Một ứng dụng phổ biến là Tối ưu hóa Ảnh hưởng (Influence Maximization - IM), nhằm xác định một tập hợp các cá nhân có thể tối đa hóa sự lan truyền ảnh hưởng trong một mạng xã hội dưới một mô hình khuếch tán cụ thể. Vấn đề này được biết đến là NP-hard và đã được nghiên cứu rộng rãi trong các lĩnh vực như marketing lan truyền (viral marketing) [35] [13]. Với sự đa dạng hóa của các nền tảng xã hội, nhiều người dùng trên các Mạng Xã hội Trực tuyến (Online Social Networks - OSNs) như Facebook và Twitter đang liên kết tài khoản của họ qua nhiều nền tảng. Những OSNs này được kết nối với nhau với các người dùng chung, được gọi là Mạng Đa Tầng (Multiplex Networks). Cấu trúc của các mạng đa tầng cho phép người dùng đăng thông tin trên nhiều OSNs đồng thời, mang lại giá trị đáng kể cho các chiến dịch marketing [36] [20] [29]. Các mô hình lan truyền thông tin bên trong mỗi mạng xã hội trực tuyến (OSN) có thể khác nhau, dẫn đến sự khác biệt trong cách thông tin lan truyền và ảnh hưởng người dùng trên các nền tảng. Do đó, việc tùy chỉnh các chiến lược tối ưu hóa ảnh hưởng sao cho hiệu quả trên nhiều nền tảng là rất quan trọng. Điều này được gọi là Tối ưu hóa Ảnh hưởng Đa tầng (Multiplex Influence Maximization - MIM).

Cho đến nay, các thuật toán Tối ưu hóa Tổ hợp (Combinatorial Optimization - CO) cho MIM [39] [13] [34] [43] [7] còn nhiều hạn chế so với các phương pháp dựa trên học máy. Các thuật toán CO gặp khó khăn trong việc tổng quát hóa đối với các đồ thị chưa thấy trước và xử lý các mạng đa tầng phức tạp. Chúng cũng gặp vấn đề về khả năng mở rộng khi làm việc với các mạng lớn. Hơn nữa, các thuật toán CO phụ thuộc vào các quy tắc hoặc thủ thuật định sẵn, làm hạn chế khả năng nắm bắt các mẫu phức tạp và các mối quan hệ phi tuyến tính trong các mạng đa tầng. Những hạn chế này làm giảm đáng kể hiệu quả của chúng trong việc tối ưu hóa việc lựa chọn các nút có ảnh hưởng. Ngược lại, các phương pháp dựa trên học máy [34] [53] [45] [43]

[37] mang lại lợi thế về khả năng tổng quát hóa, khả năng mở rộng và nắm bắt các mẫu phức tạp. Tuy nhiên, chúng vẫn gặp phải một số yếu điểm quan trọng trong MIM như sau:

a. *Tối ưu hóa không hiệu quả.* Vì MIM là một vấn đề NP-hard và mỗi lớp có thể mở rộng lên hàng tỷ, nên việc huấn luyện hiệu quả là rất cần thiết. Các phương pháp học tăng cường (RL), như những phương pháp được đề xuất trong [41] [45] [53] [34], tối ưu hóa tập hợp các nút hạt giống trong các không gian rời rạc, nhiều bằng cách tận dụng việc khám phá, cải tiến giải pháp từng bước mà không cần đầu vào ban đầu. Tuy nhiên, những phương pháp này phụ thuộc vào việc lấy mẫu ngẫu nhiên ở quy mô lớn, thường dẫn đến thời gian huấn luyện đáng kể trước khi xác định được giải pháp phù hợp và có nguy cơ bị mắc kẹt trong các tối ưu cục bộ. Để khắc phục những hạn chế này, các phương pháp dựa trên dữ liệu [7] đã được giới thiệu. Mô hình sinh này học từ các tập dữ liệu đa dạng để tạo ra các giải pháp hiệu quả. Tuy nhiên, sự thành công của nó phụ thuộc nhiều vào chất lượng của dữ liệu huấn luyện vì chỉ khi tập dữ liệu đủ đa dạng, mô hình mới có thể nắm bắt được các đặc điểm chính để tối ưu hóa. Nhìn chung, việc tạo ra một mô hình có thể tối ưu hóa các giải pháp của nó với độ phức tạp thấp vẫn là một thách thức lớn.

b. *Các mô hình ước lượng lan truyền không chính xác.* Đo lường giá trị lan truyền của một tập hợp các nút hạt giống nhất định là rất quan trọng vì nó giúp chúng ta xác định được hiệu quả của tập hợp nút hiện tại. Các phương pháp như trong [41] [34] [53] tiêu tốn thời gian đáng kể trong các mô phỏng lan truyền, trong khi các phương pháp khác như [45] [7] xây dựng các mô hình dựa trên mạng nơ-ron đồ thị (GNN) để dự đoán tổng lan truyền khi cho một tập hợp hạt giống. Các phương pháp trước đây gặp khó khăn khi mở rộng với các đồ thị lớn, trong khi các phương pháp sau gặp phải vấn đề về độ chính xác do hiện tượng làm mịn quá mức (oversmoothing) [9] trong các mô hình GNN. Thách thức này càng trở nên phức tạp hơn khi mỗi lớp trong một mạng đa tầng có thể có một mô hình lan truyền cơ bản khác nhau và có thể mở rộng đến hàng tỷ nút, làm cho việc dự đoán chính xác trở nên khó khăn hơn.

Chính vì vậy, đề án này tập trung vào việc nghiên cứu và xây dựng một mô hình học sâu tiên tiến nhằm giải quyết hiệu quả bài toán Tối ưu hóa Ảnh hưởng Đa tầng. Mô hình được đề xuất hướng tới việc khắc phục các nhược điểm về tối ưu hóa và ước lượng lan truyền đã nêu, thông qua việc kết hợp các kỹ thuật học biểu diễn, học tăng cường và kiến trúc mạng nơ-ron đồ thị chuyên biệt cho mạng đa tầng. Mục tiêu là tạo ra một giải pháp có khả năng xác định tập hạt giống tối ưu một cách hiệu quả và chính xác hơn, ngay cả trên các mạng xã hội đa tầng quy mô lớn và phức tạp.

Để trình bày nội dung một cách hệ thống và khoa học, đề án sẽ được cấu trúc thành các chương chính như sau:

- **Chương 1: Tổng quan về bài toán tối đa hóa ảnh hưởng trên mạng xã hội.**
- **Chương 2: Phương pháp đề xuất: Tối ưu hóa ảnh hưởng trên mạng xã hội đa lớp.**
- **Chương 3: Thực nghiệm và đánh giá.**

2. Tổng quan về vấn đề nghiên cứu

Tối ưu tổ hợp cho bài toán IM. Bài toán Tối ưu Ảnh hưởng (Influence Maximization - IM) thực chất là một trường hợp đơn giản hóa của Tối ưu Ảnh hưởng trên Mạng Đa Lớp (Multiplex Influence Maximization - MIM), khi chỉ giới hạn trong một mạng đơn thay vì nhiều mạng liên kết chặt chẽ. Mặc dù bài toán IM truyền thống đã đạt được nhiều tiến bộ đáng kể, nhưng MIM lại đặt ra các thách thức đặc biệt do sự tương tác phức tạp giữa các lớp mạng liên kết. Các phương pháp tiếp cận IM ban đầu chủ yếu dựa trên mô phỏng [21], thực hiện quá trình khuếch tán ảnh hưởng trên mạng lưới nhiều lần để ước lượng phạm vi ảnh hưởng. Dù trực quan, phương pháp này thường đòi hỏi tài nguyên tính toán lớn, đặc biệt với các mạng lưới lớn. Nhằm giải quyết vấn đề này, các phương pháp dựa trên proxy [31] [46] [47] đã ra đời, sử dụng các chỉ số đơn giản hơn để xấp xỉ phạm vi ảnh hưởng. Dựa trên tính chất con-mô-đun (submodularity) của quá trình khuếch tán, các thuật toán xấp xỉ như CELF++ [2] và UBLF [11] giúp chọn tập hạt giống hiệu quả với tỉ lệ xấp xỉ đảm bảo $(1 - 1/e)$.

Gần đây, thuật toán Tiptop [50] đã tạo nên bước ngoặt khi cung cấp lời giải gần chính xác cho bài toán IM với tỉ lệ tối ưu $(1 - \epsilon)$ cho bất kỳ $\epsilon > 0$. Tuy nhiên, bài toán MIM lại yêu cầu các hướng tiếp cận hoàn toàn mới do sự phức tạp bổ sung từ nhiều mạng lưới liên kết. Dù đã xuất hiện các phương pháp đầy hứa hẹn sử dụng thuật toán xấp xỉ tổ hợp [19] [3], MIM vẫn là một lĩnh vực nghiên cứu sôi động. Các hướng nghiên cứu trong tương lai bao gồm việc tích hợp học máy và khai thác các đặc điểm riêng của mạng đa lớp để đạt được các giải pháp hiệu quả và chính xác hơn.

Ứng dụng Học Máy vào bài toán IM. Các phương pháp học máy, đặc biệt là học sâu (deep learning), đã xuất hiện để vượt qua những hạn chế của các phương pháp IM truyền thống, vốn thiếu khả năng tổng quát hóa. Việc kết hợp học tăng cường (Reinforcement Learning - RL) với IM đã cho thấy tiềm năng lớn [40] [26], với các tiến bộ gần đây tập trung vào việc học biểu diễn ẩn (latent embedding) của các nút hoặc mạng để lựa chọn các nút hạt giống [41] [45] [18]. Ngoài ra, các mạng nơ-ron đồ thị (Graph Neural Networks - GNNs) cũng được nghiên cứu để mã hóa ảnh hưởng xã hội và hướng dẫn việc lựa chọn nút trong IM [6] [10]. Đặc biệt, mô hình DeepIM [53] sử dụng cách tiếp cận tạo sinh cho bài toán IM, đạt được hiệu suất hàng đầu hiện nay. Tuy nhiên, các phương pháp này chủ yếu được thiết kế cho bài toán IM trên mạng đơn và gặp khó khăn khi mở rộng sang bài toán MIM phức tạp hơn. Nguyên nhân chính đến từ các hạn chế về khả năng xử lý quy mô lớn với nhiều mạng, cũng như khó khăn trong việc nắm bắt hiệu quả các mối quan hệ khuếch tán phức tạp giữa các lớp mạng (intra-propagation và inter-propagation). Bên cạnh đó, các phương pháp này thường bị giới hạn bởi sự phụ thuộc vào mẫu quan sát. Một số công trình gần đây [34] đã kết hợp mô hình đồ thị xác suất để biểu diễn quá trình khuếch tán ảnh hưởng trong mạng đa chiều, cùng với học tăng cường để tìm tập hạt giống tối ưu. Tuy vậy, những phương pháp này vẫn đối mặt với vấn đề về khả năng mở rộng, do sự phụ thuộc vào các phương pháp truyền thống ở giai đoạn khởi đầu.

3. Mục đích nghiên cứu

Khung **REM** được đề xuất để giải quyết các thách thức của bài toán Tối đa hóa Ảnh hưởng Đa tầng (MIM). REM sử dụng **Seed2Vec** (một VAE) để biểu diễn tập hạt giống trong không gian tiềm ẩn liên tục, ít nhiễu hơn, từ đó tối ưu hóa dễ dàng hơn. Seed2Vec được khai thác như một chính sách học tăng cường (RL), chủ động khám phá các tập hạt giống có hiệu quả lan truyền cao, vượt qua hạn chế của dữ liệu huấn luyện ban đầu. Ngoài ra, REM tích hợp mô hình **PMoE** (GNN đa chuyên gia) để dự đoán chính xác sự lan truyền phức tạp mà không làm tăng độ phức tạp tính toán. REM cho kết quả vượt trội về hiệu quả lan truyền, khả năng mở rộng và thời gian suy luận so với các phương pháp tiên tiến hiện nay.

4. Đối tượng và phạm vi nghiên cứu

- Đối tượng nghiên cứu: các mạng xã hội đa lớp
- Phạm vi nghiên cứu: tập trung vào việc tối ưu hóa việc lựa chọn các đỉnh ảnh hưởng trên mạng đa lớp để lan truyền thông tin hiệu quả trên các nền tảng xã hội.

5. Phương pháp nghiên cứu

Nghiên cứu đề xuất khung **REM (Reinforced Expert Maximization)** nhằm giải quyết bài toán Tối ưu hóa Ảnh hưởng Đa tầng (MIM) thông qua kết hợp lý thuyết và thực nghiệm. Về lý thuyết, nghiên cứu tổng quan các mô hình lan truyền (**IC, LT**), kỹ thuật tối ưu hóa tổ hợp (**CO**), và học máy (**RL, GNN, VAE, MoE**), xác định rõ các thách thức chính của MIM. Thực nghiệm đánh giá REM trên các bộ dữ liệu thực tế (Facebook-Twitter, DBLP), so sánh với các phương pháp tiên tiến dựa trên hiệu suất lan truyền, thời gian huấn luyện và suy luận, khả năng mở rộng. Kết quả phân tích định lượng khẳng định hiệu quả vượt trội của REM, đồng thời thảo luận về ý nghĩa, hạn chế, và các hướng nghiên cứu tương lai trong việc ứng dụng học máy cho bài toán tối ưu trên đồ thị đa tầng phức tạp.

CHƯƠNG 1 - GIỚI THIỆU TỔNG QUAN VỀ CÁC BÀI TOÁN LAN TRUYỀN THÔNG TIN

1.1. Giới thiệu về mạng xã hội

1.1.1. Những đặc điểm chung của mạng xã hội

1.1.2. Lợi ích của mạng xã hội

1.1.3. Tác hại của mạng xã hội

1.2. Mô hình hóa lan truyền thông tin trên mạng xã hội

1.2.1. Mô hình Ngưỡng tuyến tính (LT)

1.2.2. Mô hình bậc độc lập (IC)

1.2.3. Mô hình ngăn trong dịch tễ học (SIS)

1.3. Một số bài toán lan truyền thông tin trên mạng xã hội

Trong phần này, luận đề tập trung trình bày ba bài toán chính liên quan đến lan truyền thông tin: Tối đa hóa ảnh hưởng (IM) và Tối ưu hóa ngân sách ảnh hưởng (IB).

1.3.1. Tối đa hóa ảnh hưởng (IM)

Bài toán tối đa hóa ảnh hưởng (Influence Maximization - IM) là một vấn đề quan trọng trong nghiên cứu mạng xã hội, đặc biệt trong tiếp thị và kinh doanh. Mục tiêu là chọn một tập hợp k cá thể (nút) trong mạng xã hội $G = (V, E)$ sao cho lan tỏa thông tin đạt hiệu quả cao nhất theo mô hình lan tỏa M . Đây là bài toán NP-hard, với hàm ảnh hưởng thuộc lớp #P-hard, nên thường được giải bằng các phương pháp xấp xỉ hoặc dựa trên cấu trúc mạng. Có hai nhóm thuật toán chính:

1. **Thuật toán xấp xỉ:** Đảm bảo hiệu quả lý thuyết dựa trên đặc tính mô hình lan tỏa.

2. **Thuật toán dựa trên cấu trúc mạng:** Tập dụng các đặc trưng như độ đo trung tâm, cộng đồng, hoặc đường đi.

Các biến thể của IM xem xét các yếu tố thực tiễn như chi phí, lợi ích, chủ đề, khoảng cách, thời gian, địa điểm, giúp bài toán linh hoạt và áp dụng rộng rãi trong quảng cáo, lan tỏa sản phẩm, và truyền thông xã hội.

1.3.2. Ngăn chặn ảnh hưởng (IB)

Bài toán ngăn chặn ảnh hưởng (Influence Blocking - IB) nhằm hạn chế lan tỏa thông tin không mong muốn (tin giả, nội dung kích động, tư tưởng cực đoan, virus) trong mạng xã hội, trái ngược với bài toán tối đa hóa ảnh hưởng (IM). Mục tiêu là giảm thiểu tác động tiêu cực bằng các chiến lược tối ưu, gồm hai phương pháp chính:

1. **Loại bỏ hoặc bảo vệ nút/cạnh nhạy cảm:** Chọn các đỉnh/cạnh để cách ly hoặc bảo vệ, giống như "tiêm vắc-xin", giúp miễn nhiễm với thông tin xấu.
2. **Tẩy nhiễm thông tin:** Phát tán thông tin tích cực từ các nút chiến lược để đối trọng và vô hiệu hóa nội dung tiêu cực.

Bài toán IB có ý nghĩa quan trọng trong việc bảo vệ môi trường mạng, đảm bảo an toàn thông tin, xây dựng cộng đồng lành mạnh, và chống lại tin giả, nội dung độc hại.

1.4. Kết luận chương

Chương 1 trình bày tổng quan về lan truyền thông tin trên mạng xã hội, nhấn mạnh tính hai mặt gồm lợi ích kết nối và rủi ro liên quan. Chương giới thiệu các mô hình lan truyền kinh điển như Ngưỡng Tuyên tính (LT), Bậc Độc lập (IC), và mô hình SIS để làm cơ sở lý thuyết. Đồng thời, chương cũng định nghĩa hai bài toán thực tiễn quan trọng là Tối đa hóa Ảnh hưởng (IM) và Ngăn chặn Ảnh hưởng (IB), phản ánh rõ các thách thức kỹ thuật trong quản lý thông tin. Các nghiên cứu liên quan trong lĩnh vực này cũng được đề cập nhằm tạo tiền đề cho việc phân tích sâu hơn bài toán IM ở chương tiếp theo.

CHƯƠNG 2 - TỐI ƯU HÓA ẢNH HƯỞNG ĐA TẦNG VỚI CÁC RÀNG BUỘC VỀ NGÂN SÁCH TRÊN MẠNG XÃ HỘI

2.1. Đặt vấn đề và phát biểu bài toán tối ưu hóa ảnh hưởng đa tầng trên mạng xã hội

2.1.1. Đặt vấn đề

bài toán Tối đa hóa Ảnh hưởng (IM), mục tiêu là lựa chọn một tập nhỏ các nút trong mạng xã hội để tối ưu hóa sự lan truyền thông tin. Bài toán này được mô hình hóa bằng bộ ba (S, f, Ω) , trong đó S là các trạng thái (tập con các nút), f là hàm đo mức độ ảnh hưởng, và Ω là các ràng buộc (ví dụ: chọn tối đa k nút). Đây là một bài toán tối ưu tổ hợp, thuộc lớp NP-hard, khó giải chính xác trong thời gian đa thức.


2.1.2. Phát biểu bài toán

Một mạng đa lớp với l lớp được biểu diễn bởi $\mathcal{G} = \{G_1 = (V_1, E_1), G_2 = (V_2, E_2), \dots, G_l = (V_l, E_l)\}$, trong đó mỗi phần tử bao gồm một đồ thị có hướng $G_i = (V_i, E_i)$. Nếu một nút tồn tại ở nhiều lớp, nút này được thêm vào tập hợp các nút trùng lặp của mạng đa lớp $\mathcal{G}$. Để không mất tính tổng quát, chúng tôi giả sử mỗi lớp của mạng đa lớp có cùng số lượng nút. Do đó, nếu một nút $v \in G_i$ không thuộc $G_j (i \neq j)$, chúng tôi thêm nút này vào G_j như một nút cô lập. Sau đó, đối với mỗi nút, các cạnh liên lớp được thêm vào để kết nối các bản sao liên lớp liên kề của nó trên tất cả các mạng đa lớp. Cuối cùng, chúng tôi coi tập hợp tất cả các nút của mạng đa lớp là $V = \bigcup_{i=1}^l V_i$. Trong đề án này, vì chúng tôi cho phép các lớp khác nhau của mạng đa lớp tuân theo các mô hình lan truyền ảnh hưởng khác biệt, nên cần thiết phải định nghĩa một mô hình toán học cho sự lan truyền trên mạng $\mathcal{G}$.

Định nghĩa 1 (Lan tỏa ảnh hưởng): Cho một lớp $G_i = (V, E_i)$, chúng tôi định nghĩa một tập hợp hạt giống $S \subseteq V$. Hàm δ_i đại diện cho một mô hình lan truyền ảnh hưởng trong G_i , ánh xạ từ tập lũy thừa của V tới các số thực không âm, $\delta_i: 2^V \rightarrow \mathbb{R}_{\geq 0}$. Lan tỏa ảnh hưởng, được định nghĩa là số nút kỳ vọng bị ảnh hưởng bởi tập hợp hạt giống S , được ký hiệu là $\delta_i(S)$ và được tính như sau:

$$\delta_i(S) = \lim_{m \rightarrow \infty} \frac{1}{m} \sum_{j=1}^m |T_j| \quad (1)$$

trong đó T_j đại diện cho tập hợp các nút đã được kích hoạt cuối cùng $T_j \subset V$ với tập hạt giống S tại bước mô phỏng thứ j . Mô phỏng tiếp tục cho đến khi không còn nút nào được kích hoạt hoặc cho đến khi đạt đến số bước Monte Carlo tối đa m . Tăng giá trị m sẽ cải thiện độ chính xác của việc ước lượng số nút bị ảnh hưởng. Phương pháp này áp dụng được cho hầu hết các mô hình lan truyền, bao gồm mô hình Lan truyền độc lập (Independent Cascade - IC) và Ngưỡng tuyến tính (Linear Threshold - LT) [6].



Hình 2. 1: Một ví dụ minh họa tính chất "kích hoạt trùng lặp" độc đáo của sự lan truyền ảnh hưởng trong một mạng đa lớp.

Tiếp theo, chúng ta định nghĩa mô hình lan truyền ảnh hưởng tổng thể δ trong mạng đa lớp $\mathcal{G}$. Đầu tiên, khi một nút trùng lặp v được kích hoạt trong một lớp đồ thị G_i , các bản sao liên lớp tương ứng của nó trong các lớp khác cũng sẽ được kích hoạt một cách xác định. Hiện tượng này được gọi là "kích hoạt trùng lặp" [12] [15] và được minh họa trong Hình 2.3. Thứ hai, khi tính số lượng kỳ vọng các nút bị ảnh hưởng trong toàn bộ mạng đa lớp $\mathcal{G}$, chúng ta coi các nút trùng lặp là một thực thể duy nhất thay vì đếm chúng nhiều lần. Điều này có nghĩa là khi đếm các nút bị ảnh hưởng trên tất cả các lớp, chúng ta không cộng thêm các bản sao trùng lặp do kích hoạt trùng lặp gây ra. Do đó, ảnh hưởng tổng thể $\delta(S)$ kết hợp ảnh hưởng độc lập từ mỗi lớp đồng thời tính đến các kích hoạt trùng lặp:

$$\delta(S) = \lim_{m \rightarrow \infty} \frac{1}{m} \sum_{j=1}^m \left| \bigcup_{i=1}^l T_{ij}(S) \right| \quad (2)$$


trong đó $T_{ij} \subset V$ đại diện cho tập các nút đã được kích hoạt cuối cùng trong lớp i với tập hạt giống S tại bước mô phỏng thứ j . Giờ đây, chúng ta đã sẵn sàng định nghĩa bài toán MIM như sau:

Định nghĩa 2 (Tối ưu hóa Lan tỏa Ảnh hưởng trong Mạng Đa Lớp (MIM)): Cho một đồ thị đa lớp $\mathcal{G} = (G_1 = (V, E_1), \delta_1), \dots, (G_l = (V, E_l), \delta_l)$ và một ngân sách $b \in \mathbb{N}$. Cụ thể, tập hạt giống S được biểu diễn dưới dạng một vector nhị phân $\mathbf{x} \in \mathbb{R}^{1 \times |V|}$, trong đó mỗi phần tử x_j tương ứng với một nút v_j trong V . Cụ thể, $x_j = 1$ nếu v_j được đưa vào tập hạt giống, và $x_j = 0$ nếu không. Giả sử chúng ta có một tập dữ liệu huấn luyện gồm các cặp chỉ số tập hạt giống (x, y) , trong đó x đại diện cho một tập hạt giống và $y = \delta(\mathbf{x})$ là số nút bị ảnh hưởng tổng cộng tương ứng. Bài toán MIM yêu cầu chúng ta tìm một tập hợp nút hạt giống tối ưu $\tilde{\mathbf{x}}$ có kích thước không vượt quá b để tối đa hóa lan tỏa ảnh hưởng tổng thể $\delta(\mathbf{x})$ được tính trong mạng đa lớp. Bài toán này được mô tả như sau:

$$\tilde{\mathbf{x}} = \arg \max_{|\mathbf{x}| \leq b} \delta(\mathbf{x}) \quad (3)$$

Đối với mỗi lớp $G_i \in \mathcal{G}$, nhiều thuật toán tham lam [33] [25] [34] [10] đã đạt được bảo đảm hiệu năng $(1 - 1/e)$, nếu δ_i là hàm con mô đun và đơn điệu tăng [6]. Nếu tất cả δ_i của mọi G_i thỏa mãn tính chất Tổng quát Định hình con mô đun (GDS), thì δ là hàm con mô đun [12].

2.2. Khung mô hình REM cho bài toán tối ưu hóa ảnh hưởng trên mạng đa tầng



Hình 2. 2: Sơ đồ mô tả quy trình của REM trong việc giải quyết bài toán MIM.

Đầu tiên, REM sử dụng Seed2Vec để nhúng biểu diễn phức tạp của tập hạt giống vào không gian liên tục và ít nhiễu hơn. Sau đó, REM khám phá và tạo ra các tập hạt giống đa dạng từ không gian ẩn này. REM kiểm soát chất lượng của việc tạo tập hạt giống thông qua PMoE, một mô hình có khả năng học và dự đoán chính xác sự lan truyền của tập hạt giống trong mạng multiplex quy mô lớn. Sau khi các tập tổng hợp được tạo ra, chúng được lưu trữ trong bộ nhớ ưu tiên PRM. Để tránh hiện tượng sụp đổ mô hình hoặc quên lãng thảm khốc, các tập hạt giống hàng đầu, được PMoE dự đoán có đóng góp lớn nhất cho sự lan truyền trong mạng multiplex, được kết hợp với tập dữ liệu ban đầu để tạo thành tập dữ liệu mới nhằm huấn luyện lại mô hình. Quá trình này củng cố khả năng sản xuất các tập hạt giống chất lượng cao hơn trong các lần lặp lại sau.

2.2.1. Mô hình học biểu diễn vector cho tập hạt giống phức tạp

2.2.2. Khám phá tập hạt giống tiềm ẩn

2.2.3. Lan truyền hỗn hợp các chuyên gia

2.3. Kết luận chương

CHƯƠNG 3: THỰC NGHIỆM VÀ ĐÁNH GIÁ

3.1. Thiết lập thực nghiệm

3.1.1. Dữ liệu và tham số

Mục tiêu chính của chúng tôi là đánh giá tác động của sự lan tỏa ảnh hưởng trong các kịch bản khác nhau trong bài toán Tối ưu Hóa Ảnh Hưởng (Influence Maximization - IM). Các thí nghiệm của chúng tôi tập trung vào hai mô hình lan truyền chủ đạo trong IM: mô hình Ngưỡng Tuyến Tính (Linear Threshold - LT) và mô hình Cascade Độc Lập (Independent Cascade - IC).

Hyperparameter Setting. Chúng tôi đã thực hiện các thí nghiệm trên một hệ thống được trang bị bộ xử lý Intel(R) Core i9-13900k, RAM 128 GB và hai GPU Nvidia RTX 4090 với 24GB VRAM mỗi chiếc. Đối với mỗi phương pháp so sánh, chúng tôi thiết lập các siêu tham số theo bài báo gốc của chúng và tinh chỉnh trên từng tập dữ liệu. Đối với cấu hình của mỗi mô hình khuếch tán, chúng tôi sử dụng phiên bản cascade có trọng số của mô hình IC, cụ thể là xác suất lan truyền $p_{u,v} = 1/d_v^{in}$ (d_v^{in} là bậc trong của nút v) cho mỗi cạnh $e = (u, v)$ trên đồ thị G . Đối với mô hình LT, ngưỡng θ được đặt là 0.5 cho mỗi nút v . Với REM, siêu tham số (Bảng 3.1) được lựa chọn dựa trên hiệu suất, ổn định và hiệu quả huấn luyện.

Bảng 3. 1: Giá trị các siêu tham số của mô hình.

Tham số	Giá trị
Tốc độ học cho Mô hình VAE	0.003
Tốc độ học cho Mô hình PMOE	0.001
Bộ tối ưu	Adam
Số bước mỗi tập	400
Số tập	30
Kích thước minibatch	256
Trọng số KL	0.55

Số lượng chuyên gia	8
Tỷ lệ dropout	0.2
Hệ số entropy	0.1

Dữ liệu. Các thí nghiệm của chúng tôi sử dụng nhiều tập dữ liệu mạng đa lớp (multiplex network) với các loại tương tác và hệ thống đa dạng.

Bảng 3. 2: Thống kê các bộ dữ liệu sử dụng.

Dữ liệu	Số nút	Số cạnh
Cora-ML	2.708	7.981
Celegans	3.879	8.181
Arabidopsis	6.980	18.654
NYClimateMarch2014	102.439	353.495
ParisAttack2015	1.896.221	4.163.947

3.1.2. Phương pháp so sánh

Chúng tôi đánh giá hiệu suất của REM so với hai nhóm phương pháp tối ưu hóa ảnh hưởng: (1) phương pháp truyền thống gồm ISF (tham lam) và KSN (thuật toán ba lô) cho mạng đa lớp; (2) phương pháp học sâu gồm ToupleGDD, GCOMB, DeepIM (mạng đơn lớp), và MIM-Reasoner (mạng đa lớp dùng học tăng cường). Ngoài ra, chúng tôi kiểm chứng hai biến thể của REM: REM-NonRL (không dùng học tăng cường) và REM-NonMixture (không sử dụng cấu trúc đa chuyên gia). Việc so sánh dựa trên hai chỉ số: tổng ảnh hưởng lan truyền (số nút được kích hoạt) và thời gian suy diễn (giây).

3.2. Kết quả và đánh giá

3.2.1. Khả năng lan truyền thông tin

IM dưới mô hình IC. Các phương pháp được đánh giá trên năm tập dữ liệu dưới mô hình lan tỏa IC với ngân sách là 1%, 5%, 10% và 20% tổng số nút của mạng. Như được chỉ ra trong Bảng 3.3-3.8, REM liên tục vượt trội hơn các phương pháp khác, đặc biệt là trên các tập dữ liệu lớn như NYClimateMarch2014 và

ParisAttack2015. Các phương pháp truyền thống (ISF, KSN) hoạt động tốt trên các đồ thị nhỏ nhưng gặp khó khăn khi mở rộng với các đồ thị lớn hơn và ngân sách cao hơn. Các phương pháp học mạng đơn (GCOMB, TOUPLEGDD, DEEPIM) tụt lại phía sau do không thể thích ứng với mạng đa lớp. Trong khi MIM-Reasoner đạt được kết quả mạnh mẽ trên các mạng đa lớp lớn, nó vẫn bị REM vượt qua. Đặc biệt, các biến thể của REM (REM-NonRL, REM-NonMixture) cho thấy sự giảm sút hiệu suất đáng kể, nhấn mạnh tầm quan trọng của các thành phần chính trong REM.

Bảng 3. 3: So sánh hiệu suất dưới mô hình lan truyền IC (Cora-ML).

Cora-ML				
	1%	5%	10%	20%
ISF	398.34	778.62	979.87	1368.56
KSN	398.31	778.62	979.10	1366.03
GCOMB	347.11	766.02	976.14	1251.52
ToupleGDD	349.01	721.42	862.42	1132.66
DeepIM	311.52	606.82	826.41	1179.45
MIM-Reasoner	398.22	778.02	978.95	1363.35
REM-NoneRL	321.24	732.84	880.51	1151.68
REM-NonMixture	343.16	736.42	921.24	1301.55
REM	347.34	765.48	965.04	1404.14

Bảng 3. 4: So sánh hiệu suất dưới mô hình lan truyền IC (Celegans).

Celegans				
	1%	5%	10%	20%
ISF	1465.86	2298.01	2571.92	2819.26
KSN	1382.86	2176.32	2335.44	2620.10
GCOMB	1389.63	1896.86	2237.37	2550.61
ToupleGDD	1279.28	1905.23	2117.74	2411.14

DeepIM	1275.66	1527.25	1938.58	2251.53
MIM-Reasoner	1432.39	2199.26	2389.91	2645.24
REM-NoneRL	1301.22	1884.95	2098.16	2451.87
REM-NonMixture	1387.67	2062.79	2304.15	2695.28
REM	1445.16	2278.07	2585.06	2904.03

Bảng 3. 5: So sánh hiệu suất dưới mô hình lan truyền IC (Arabidopsis).

Arabidopsis				
	1%	5%	10%	20%
ISF	2415.04	3140.58	3871.10	4694.16
KSN	2282.72	2941.54	3621.26	4641.34
GCOMB	2315.44	3097.97	3622.08	4547.63
ToupleGDD	2044.67	2856.37	3487.41	4483.27
DeepIM	1993.37	2397.89	3328.33	4073.50
MIM-Reasoner	2396.95	2989.15	3729.39	4621.54
REM-NoneRL	2076.31	2421.13	3399.34	4120.51
REM-NonMixture	2317.39	2982.67	3712.35	4611.27
REM	2430.84	3181.26	3964.45	4701.75

Bảng 3. 6: So sánh hiệu suất dưới mô hình lan truyền IC. – biểu thị lỗi hết bộ nhớ. (Giá trị tốt nhất được in đậm.) (NYClimateMarch2014)

NYClimateMarch2014				
	1%	5%	10%	20%
ISF	-	-	-	-
KSN	-	-	-	-
GCOMB	2093.32	7228.02	11780.29	16933.89

ToupleGDD	1821.43	6714.98	10231.81	17822.21
DeepIM	1893.02	6409.32	8064.77	14269.49
MIM-Reasoner	2101.86	7387.91	11984.55	21062.87
REM-NoneRL	2057.82	6835.44	8564.63	16021.63
REM-NonMixture	2215.82	7124.29	10034.71	18932.40
REM	2162.83	7465.96	12834.45	23142.83

Bảng 3. 7: So sánh hiệu suất dưới mô hình lan truyền IC. – biểu thị lỗi hết bộ nhớ. (Giá trị tốt nhất được in đậm.) (ParisAttack2015)

ParisAttack2015				
	1%	5%	10%	20%
ISF	-	-	-	-
KSN	-	-	-	-
GCOMB	114672.50	180977.09	356187.81	587891.16
ToupleGDD	102872.11	171992.43	335298.85	563387.05
DeepIM	83972.39	149237.59	281298.85	480393.42
MIM-Reasoner	129650.48	217291.02	379932.17	608192.57
REM-NoneRL	87109.27	152621.23	298923.41	515237.59
REM-NonMixture	125098.55	207621.48	380274.03	605875.67
REM	147193.96	229769.76	402372.32	637621.59

3.2.2. So sánh thời gian chạy

3.2.3. Ảnh hưởng của số lần khám phá môi trường

3.2.4. Kết quả các biến thể khác của mô hình

3.3. Kết luận chương

KẾT LUẬN

Đề án này đã tập trung nghiên cứu và giải quyết bài toán Tối ưu hóa Ảnh hưởng Đa tầng (Multiplex Influence Maximization - MIM), một vấn đề phức tạp và có ý nghĩa thực tiễn cao trong bối cảnh mạng xã hội đa nền tảng ngày càng phát triển. Bài toán MIM đặt ra nhiều thách thức hơn so với Tối ưu hóa Ảnh hưởng (IM) truyền thống do sự tương tác phức tạp và động lực lan truyền độc đáo giữa các lớp mạng, điển hình là hiện tượng "kích hoạt trùng lặp". Các phương pháp hiện có, bao gồm cả thuật toán tối ưu tổ hợp và các kỹ thuật học máy ban đầu, thường gặp khó khăn về khả năng mở rộng, độ chính xác trong ước lượng lan truyền và hiệu quả tối ưu hóa trong không gian giải pháp lớn và nhiều của mạng đa tầng.

Để giải quyết những thách thức này, đề án đã đề xuất một khung làm việc học sâu đa tầng mới mang tên Tối đa hóa Chuyên gia Tăng cường (Reinforced Expert Maximization - REM). Đóng góp cốt lõi của REM nằm ở việc tích hợp sáng tạo các cơ chế học sâu và học tăng cường. REM bắt đầu bằng việc sử dụng Seed2Vec, một mô hình dựa trên Bộ tự mã hóa biến phân (VAE), để học biểu diễn hiệu quả cho các tập hạt giống phức tạp, ánh xạ chúng vào một không gian tiềm ẩn liên tục, ít nhiễu hơn, tạo điều kiện thuận lợi cho việc tối ưu hóa. Nhận thấy giới hạn của việc chỉ học từ dữ liệu ban đầu, REM tiếp tục coi Seed2Vec như một tác nhân học tăng cường (RL), chủ động khám phá không gian tiềm ẩn này để tạo ra các tập hạt giống tổng hợp, đa dạng và có khả năng lan truyền cao, vượt qua giới hạn của dữ liệu huấn luyện và tránh bị mắc kẹt ở các cực tiểu cục bộ. Để dẫn dắt quá trình khám phá và đánh giá chất lượng các tập hạt giống tiềm năng, REM giới thiệu kiến trúc Hỗn hợp Chuyên gia Lan truyền (PMoE). Kiến trúc này sử dụng một tập hợp các Mạng nơ-ron đồ thị (GNN) chuyên biệt với độ sâu khác nhau, kết hợp với một mạng định tuyến thông minh, nhằm ước lượng chính xác và hiệu quả các mẫu lan truyền phức tạp trong mạng đa tầng quy mô lớn, giảm thiểu hiện tượng làm mịn quá mức và tăng cường khả năng mô hình hóa động lực học tinh vi của mạng. Sự kết hợp giữa việc biểu diễn hiệu quả, khám phá thông minh và ước lượng lan truyền chính xác tạo nên sức mạnh tổng thể của khung REM.

Quá trình thực nghiệm trên nhiều bộ dữ liệu mạng đa lớp thực tế (Cora-ML, Celegans, Arabidopsis, NYClimatMarch2014, ParisAttack2015) dưới cả hai mô hình lan truyền phổ biến (IC và LT) đã chứng minh hiệu quả vượt trội của REM. Kết quả cho thấy REM liên tục đạt được mức độ lan tỏa ảnh hưởng cao hơn đáng kể so với các phương pháp tiên tiến hiện có, bao gồm cả các thuật toán tối ưu tổ hợp chuyên biệt cho MIM và các phương pháp học sâu khác. Đặc biệt, REM thể hiện khả năng mở rộng tốt trên các mạng quy mô lớn và duy trì thời gian suy luận cạnh tranh. Các phân tích sâu hơn về các biến thể mô hình và lựa chọn kiến trúc cũng đã khẳng định vai trò quan trọng của từng thành phần được đề xuất trong việc đạt được hiệu suất cao. **Đáng chú ý, những đóng góp và kết quả nghiên cứu chính của luận văn đã được chấp nhận đăng và sẽ được trình bày tại Hội nghị AAAI Conference on Artificial Intelligence (AAAI) 2025, tổ chức tại Philadelphia, Mỹ, minh chứng cho tính mới và ý nghĩa khoa học của công trình.**

Mặc dù đạt được những kết quả đáng khích lệ, nghiên cứu này vẫn còn một số hạn chế. Hiệu quả của REM vẫn có thể phụ thuộc vào chất lượng của tập dữ liệu hạt giống ban đầu, mặc dù cơ chế RL đã giúp giảm thiểu phần nào sự phụ thuộc này. Chi phí tính toán cho quá trình huấn luyện, đặc biệt là giai đoạn khám phá bằng RL và huấn luyện lại mô hình, có thể còn cao và cần được tối ưu hóa thêm.

Hướng nghiên cứu trong tương lai có thể tập trung vào việc cải thiện hiệu quả huấn luyện của REM, khám phá các chiến lược RL tiên tiến hơn để tối ưu hóa quá trình khám phá tập hạt giống. Việc mở rộng REM để xử lý các mạng đa tầng động, nơi cấu trúc mạng và mối quan hệ thay đổi theo thời gian, cũng là một hướng đi đầy hứa hẹn, phản ánh đúng hơn bản chất của các mạng xã hội thực tế. Ngoài ra, việc tích hợp các thuộc tính ngữ nghĩa của nút hoặc nội dung thông tin lan truyền vào mô hình có thể làm tăng thêm độ chính xác và tính ứng dụng thực tế của giải pháp. Cuối cùng, việc áp dụng các ý tưởng cốt lõi của REM, đặc biệt là sự kết hợp giữa học biểu diễn, học tăng cường và mô hình dự đoán chuyên biệt, cho các bài toán tối ưu tổ hợp khác trên đồ thị phức tạp cũng là một tiềm năng cần được khai thác.

CÔNG BỐ KHOA HỌC

Tiêu đề bài báo: REM: A SCALABLE REINFORCED MULTI-EXPERT FRAMEWORK FOR MULTIPLEX INFLUENCE MAXIMIZATION

Hội nghị: Hội nghị AAAI 2025

Điểm tác động nghiên cứu: 32.10

Ngày nhận bài: 15 tháng 8 năm 2024

Ngày chấp nhận: 9 tháng 12 năm 2024

Ngày nộp bản chỉnh sửa: 19 tháng 12 năm 2024

Tác giả: Huyen Nguyen, Hieu Dam, Nguyen Do, Cong Tran, Cuong Pham

Vị trí: Tác giả chính

TÀI LIỆU THAM KHẢO

- [1] A. Antelmi, G. Cordasco, C. Spagnuolo, and P. Szufel. Social influence maximization in hypergraphs. *Entropy*, 23(7):796, 2021.
- [2] A. Goyal, W. Lu, and L. Lakshmanan. CELF++: Optimizing the greedy algorithm for influence maximization in social networks. In *Proceedings of the 20th International Conference Companion on World Wide Web, WWW 2011*, pages 47–48, 2011.
- [3] A. Kuhnle, M. A. Alim, X. Li, H. Zhang, and M. T. Thai. Multiplex influence maximization in online social networks with heterogeneous diffusion models. *IEEE Transactions on Computational Social Systems*, 5(2):418–429, 2018.
- [4] A. K. McCallum, K. Nigam, J. Rennie, and K. Seymore. Automating the construction of internet portals with machine learning. *Information Retrieval*, 3(2):127–163, 2000.
- [5] B. W. Dolhansky and J. A. Bilmes. Deep submodular functions: Definitions and learning. In *Advances in Neural Information Processing Systems*, volume 29, 2016.
- [6] C. Ling, J. Jiang, J. Wang, and L. Zhao. Source localization of graph diffusion via variational autoencoders for graph inverse problems. In *Proc. of the KDD*, 2022.
- [7] C. Ling, J. Jiang, J. Wang, M. T. Thai, R. Xue, J. Song, M. Qiu, and L. Zhao. Deep graph representation learning and optimization for influence maximization. In *International Conference on Machine Learning*, pages 21350–21361. PMLR, 2023.
- [8] C. Stark, B.-J. Breitkreutz, T. Reguly, L. Boucher, A. Breitkreutz, and M. Tyers. BioGRID: A general repository for interaction datasets. *Nucleic acids research*, 34:D535–9, 2006
- [9] C. Cai and Y. Wang. A note on over-smoothing for graph neural networks. *arXiv preprint arXiv: 2006.13318*, 2020.

- [10] C. Ling, T. Chowdhury, J. Jiang, J. Wang, X. Zhang, H. Chen, and L. Zhao. DeepGAR: Deep graph learning for analogical reasoning. In 2022 IEEE International Conference on Data Mining (ICDM), pages 1065–1070. IEEE, 2022.
- [11] C. Zhou, P. Zhang, W. Zang, and L. Guo. On the upper bounds of spread for greedy algorithms in social network influence maximization. *IEEE Transactions on Knowledge and Data Engineering*, 27(10):2770–2783, 2015.
- [12] D. Horgan, J. Quan, D. Budden, G. Barth-Maron, M. Hessel, H. Van Hasselt, and D. Silver. Distributed prioritized experience replay. *arXiv preprint arXiv:1803.00933*, 2018. D. P. Kingma. Auto-encoding variational bayes. *arXiv preprint arXiv:1312.6114*, 2013.
- [13] D. Kempe, J. Kleinberg, and E. Tardos. Maximizing the spread of influence through a social network. In *Proc. of the KDD*, 2003.
- [14] D. F. Nettleton. Data mining of social networks represented as graphs. *Computer Science Review*, 7:1–34, 2013.
- [15] D. P. Kingma and M. Welling. Auto-encoding variational bayes. In *International Conference on Learning Representations*, 2013.
- [16] E. Omodei, M. D. De Domenico, and A. Arenas. Characterizing interactions in online social networks during exceptional events. *Frontiers in Physics*, 3, 2015.
- [17] F. Bonchi. Influence propagation in social networks: A data mining perspective. In 2011 IEEE/WIC/ACM International Conferences on Web Intelligence and Intelligent Agent Technology, 1:2–2. IEEE, 2011.
- [18] H. Li, M. Xu, S. S. Bhowmick, J. S. Rayhan, C. Sun, and J. Cui. PIANO: Influence maximization meets deep reinforcement learning. *IEEE Transactions on Computational Social Systems*, 2022.
- [19] H. Zhang, D. T. Nguyen, H. Zhang, and M. T. Thai. Least cost influence maximization across multiple social networks. *IEEE/ACM Transactions on Networking*, 24(2):929–939, 2016.

- [20] H. Zhang, D. T. Nguyen, H. Zhang, and M. T. Thai. Least cost influence maximization across multiple social networks. *IEEE/ACM Transactions on Networking*, 24(2):929–939, 2016.
- [21] H. Zhang, X. Chen, Y. Peng, G. Kou, and R. Wang. The interaction of multiple information on multiplex social networks. *Information Sciences*, 605:366–380, 2022.
- [22] J. Leskovec, A. Krause, C. Guestrin, C. Faloutsos, J. VanBriesen, and N. Glance. Cost-effective outbreak detection in networks. In *Proceedings of the 13th ACM SIGKDD international conference on Knowledge discovery and data mining*, pages 420–429, 2007.
- [23] J. Wu and D. Li. Modeling and maximizing information diffusion over hypergraphs based on deep reinforcement learning. *Physica A: Statistical Mechanics and its Applications*, 629:129193, 2023.
- [24] J. S. Lim, S. Y. Ri, B. D. Egan, and F. A. Biocca. The cross-platform synergies of digital video advertising: Implications for cross-media campaigns in television, Internet and mobile TV. *Computers in Human Behavior*, 48:463–472, 2015.
- [25] J. Zhu, S. Ghosh, W. Wu, and C. Gao. Profit maximization under group influence model in social networks. In *International Conference on Computational Data and Social Networks*, pages 108–119. Springer, 2019.
- [26] J. Zhu, J. Zhu, S. Ghosh, W. Wu, and J. Yuan. Social influence maximization in hypergraph in social networks. *IEEE Transactions on Network Science and Engineering*, 6(4):801–811, 2019.
- [27] K. Ali, C.-Y. Wang, and Y.-S. Chen. Boosting reinforcement learning in competitive influence maximization with transfer learning. In *2018 IEEE/WIC/ACM International Conference on Web Intelligence (WI)*, pages 395–400. IEEE, 2018.
- [28] M. Contisciani, E. A. Power, and C. De Bacco. Community detection with node attributes in multilayer networks. *Scientific Reports*, 2020.

- [29] M. De Domenico and E. G. Altmann. Unraveling the origin of social bursts in collective attention. *Scientific reports*, 10(1):4629, 2020.
- [30] M. Jalili, Y. Orouskhani, M. A. Mehrabadi, N. Alipourfard, and M. Perc. Link prediction in multiplex online social networks. *Royal Society Open Science*, 4(2):160863, 2017.
- [31] M. Katukuri, M. Jagarapu, and others. CIM: clique-based heuristic for finding influential nodes in multilayer networks. *Applied Intelligence*, 52(5):5173–5184, 2022.
- [32] M. Kimura and K. Saito. Tractable models for information diffusion in social networks. In *Knowledge Discovery in Databases: PKDD 2006*, pages 259–271. Springer Berlin Heidelberg, 2006.
- [33] M. Xie, X.-X. Zhan, C. Liu, and Z.-K. Zhang. Influence maximization in hypergraphs. *arXiv preprint arXiv:2206.01394*, 2022.
- [34] N. M. Shazeer, A. Mirhoseini, K. Maziarz, A. Davis, Q. V. Le, G. E. Hinton, and J. Dean. Outrageously large neural networks: The sparsely-gated mixture-of-experts layer. In *International Conference on Learning Representations*, 2017.
- [35] N. H. K. Do, T. Chowdhury, C. Ling, L. Zhao, and M. T. Thai. MIM-Reasoner: Learning with theoretical guarantees for multiplex influence maximization. In *International Conference on Artificial Intelligence and Statistics*, pages 2296–2304, 2024.
- [36] P. Domingos and M. Richardson. Mining the network value of customers. In *Proceedings of the Seventh ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pages 57–66. ACM, 2001.
- [37] P. Vikatos, P. Gryllos, and C. Makris. Marketing campaign targeting using bridge extraction in multiplex social network. *Artificial Intelligence Review*, 53:2335–2360, 2020.

- [38] Q. Li, Z. Han, and X.-M. Wu. Deeper insights into graph convolutional networks for semi-supervised learning. In AAAI Conference on Artificial Intelligence, 2018.
- [39] Q. Zhan, J. Zhang, S. Wang, P. S. Yu, and J. Xie. Influence maximization across partially aligned heterogeneous social networks. In Pacific-Asia conference on knowledge discovery and data mining, pages 58–69. Springer, 2015.
- [40] S. S. Singh, A. Kumar, K. Singh, and B. Biswas. C2IM: Community based context-aware influence maximization in social networks. *Physica A: Statistical Mechanics and its Applications*, 514:796–818, 2019.
- [41] S.-C. Lin, S.-D. Lin, and M.-S. Chen. A learning-based framework to handle multi-round multi-party influence maximization on social networks. In Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, pages 695–704, 2015.
- [42] S. Manchanda, A. Mittal, A. Dhawan, S. Medya, S. Ranu, and A. Singh. GCOMB: Learning budget-constrained combinatorial algorithms over billion-sized graphs. In Advances in Neural Information Processing Systems, pages 20000–20011, 2020.
- [43] S. Banerjee, M. Jenamani, and D. K. Pratihari. ComBIM: A community-based solution approach for the Budgeted Influence Maximization Problem. *Expert Systems with Applications*, 125:1–13, 2019.
- [44] S. S. Singh, K. Singh, A. Kumar, and B. Biswas. MIM2: Multiple influence maximization across multiple social networks. *Physica A: Statistical Mechanics and its Applications*, 526:120902, 2019.
- [45] S. Bai, F. Zhang, and P. H. S. Torr. Hypergraph convolution and hypergraph attention. *Pattern Recognit.*, 110:107637, 2021.
- [46] T. Chen, S. Yan, J. Guo, and W. Wu. ToupleGDD: A finedesigned solution of influence maximization by deep reinforcement learning. arXiv preprint arXiv:2210.07500, 2022.

- [47] W. Chen, C. Wang, and Y. Wang. Scalable influence maximization for prevalent viral marketing in large-scale social networks. In Proceedings of the 16th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, pages 1029–1038. ACM, 2010b.
- [48] W. Chen, Y. Yuan, and L. Zhang. Scalable influence maximization in social networks under the linear threshold model. In 2010 IEEE International Conference on Data Mining, pages 88–97. IEEE, 2010a.
- [49] W. O. Kermack and A. G. McKendrick. A contribution to the mathematical theory of epidemics. Proceedings of the royal society of london. Series A, Containing papers of a mathematical and physical character, 115(772):700–721, 1927.
- [50] X. Chen, L. Deng, Y. Zhao, X. Zhou, and K. Zheng. Community-based influence maximization in location-based social network. WWWJ, 24(6):1903–1928, 2021.
- [51] X. Li, J. D. Smith, T. N. Dinh, and M. T. Thai. Tiptop:(almost) exact solutions for influence maximization in billion-scale networks. IEEE/ACM Transactions on Networking, 27(2):649–661, 2019.
- [52] Y. Li, G. Wang, X. Ji, Y. Xiang, and D. Fox. DeepIM: Deep iterative matching for 6D pose estimation. International Journal of Computer Vision, 2018.
- [53] Y. Tang, X. Xiao, and Y. Shi. Influence maximization: Nearoptimal time complexity meets practical efficiency. In Proc. of the SIGMOD, pages 75–86, 2014.
- [54] Z. Yuan, M. Shao, and Z. Chen. Graph bayesian optimization for multiplex influence maximization. In Thirty-Eighth AAAI Conference on Artificial Intelligence, AAAI 2024, pages 22475–22483. AAAI Press, 2024.
- [55] Z. Liaghat, A. Rasekh, and A. Mahdavi. Application of data mining methods for link prediction in social networks. Social Network Analysis and Mining, 3(1):97–111, 2013.

