具备社会意识的推荐系统缓解观点聚类

Lukas Sch¨uepp苏黎世联邦理工学院
lukaschu@ethz.ch

Carmen Amo Alonso斯坦福大学 camoalon@stanford.edu

Florian D¨orfler苏黎世联邦理工学院
dorfler@ethz.ch

Giulia DePasquale埃因霍温理工大学
g.de.pasquale@tue.nl

arXiv:2601.02412v1 [cs.IR] 2 Jan 2026

摘要

推荐系统通过将用户与创作者的内容相匹配来塑造在线互动，从而最大限度地提高参与度。反过来，创作者会调整内容以符合用户偏好并提升人气。同时，用户偏好也会受到推荐系统所推荐内容以及社交圈内分享内容的影响而不断变化。这一反馈循环使用户、创作者和推荐算法之间产生复杂的相互作用，成为过滤气泡和观点极化的主要成因。我们开发了一种社交网络感知推荐系统，明确考虑用户与创作者之间的反馈互动，并有策略地利用用户自身社交网络的拓扑结构来促进多样化。我们的方法表明，在推荐系统设计中考虑并利用用户的社交网络，对于调和过滤气泡效应、兼顾内容多样性与个性化至关重要。可以证明，观点聚类与推荐内容对用户意见的影响呈正相关。最终，所提出的方法展现了具备社会意识的推荐系统在应对观点极化和聚类现象方面的强大作用。

1 引言

随着流媒体服务和电子商务平台的蓬勃发展，对高效内容推荐系统（RS）的需求日益增加 Linden et al. (2003); Covington et al. (2016); Gomez- Uribe & Hunt (2016)。这些系统从海量数字内容中筛选个性化内容，为用户提供推荐，从而提升用户体验，并最终最大限度地提高平台参与度 Li et al. (2024); Raza et al. (2025)。另一方面，通过持续推广符合用户偏好的内容，推荐系统缩小了用户接触到的信息多样性，从而助长回音室效应和观点极化 Cinus et al. (2022)。尽管研究者已付出诸多努力，如何在提高用户满意度的同时遏制观点聚类等负面全局影响，仍是一个难题 Slokom et al. (2025); Su et al. (2013)。一个关键问题是，如何在满足个体用户需求与防止社会层面有害后果之间取得平衡 Lanzetti 等人（2023）。

推荐系统技术背后的基本原则始终如一：利用用户历史互动模式和个人资料信息生成个性化推荐。在这一背景下，协同过滤、基于内容的过滤，以及结合这两种方法的混合方法 Li et al.（2024），已成为该领域的主流范式。然而，尽管个性化能够提升个体层面的用户满意度，却也加剧了观点激进化等负面的宏观现象 Rossi 等人（2022）；Lanzetti 等人（2023）；Lin 等人（2024）。传统的应对措施或许在孤立的实验环境中有效，却未能考虑到内容创作者会采取策略，调整其内容材料以吸引潜在受众 Lin 等人（2024）；Dean 等人（2024b）。此外，大多数方法忽视了用户之间的社会互动，因此限制了其在宏观层面发挥作用的能力。

事实上，个体并非孤立行动，而是置身于社会情境之中，与他人的互动会影响其偏好和行为 Proskurnikov & Tempo（2017）；Mei 等人（2022）。由此，出现了一种名为社交推荐系统的推荐范式：该范式利用社交网络图和用户-项目评分矩阵，以生成更准确且个性化的推荐 Ma 等人（2008）；Yang 等人（2014）。与社交推荐系统不同，我们关注的并非将邻居的观点作为预测未来偏好的依据。相反，我们旨在动态利用社交网络的结构作为一种控制工具，以塑造长期的意见动力学，从而缓解观点聚类。

然而，社交推荐系统中一个至关重要却尚未得到充分探索的方面是：如何利用社交网络，在不损害用户满意度的情况下减少有害内容 Hassan (2019)。我们认为，观点极化是一种集体现象，因此会受到社会互动的影响；要让推荐系统缓解这类不良效应，仅提升单个用户接触到的内容多样性还不够。用户嵌入社交网络的情况，是设计可信推荐系统的关键因素 Hassan (2019); Chandrasekaran 等人（2024）。

本文探讨一个根本问题：推荐系统如何高效利用用户之间的社会互动，以减轻全局聚类效应，同时维持较高的用户满意度？我们表明，通过明确建模用户在社交网络中的动态相互作用、创作者的内容与推荐系统，便有可能在用户满意度与观点多样性之间取得更好的平衡。

贡献我们提出一种新颖的理论框架，用于对推荐系统领域进行建模，其中用户、内容创作者与推荐系统之间存在动态互动，且用户嵌入于社交网络中。我们利用用户的网络结构，开发一种基于优化的推荐系统，在维持较高用户满意度的同时缓解观点聚类。与以往方法不同，我们明确建模用户、创作者与推荐系统之间的互动。我们的主要贡献如下：

• 我们提出了一个框架，用于捕捉彼此存在社交联系的用户、策略性内容创作者与推荐系统之间的动态互动，并刻画内容个性化与观点极化之间的关系。

• 我们证明，采用贪心策略优化用户满意度的推荐系统会导致创作者之间形成观点簇。

• 我们提出一种社交网络感知推荐器， $RS(d)$，其中参数 d（用户跳数）用于控制用户满意度与创作者聚类程度之间的权衡：较低的 d 会带来更高的满意度，但也会形成更多簇；较高的 d 则会减少簇的数量，但代价是满意度降低。

• 我们通过实验测试了该算法，并展示了仅考虑互动最大化时，推荐系统会加剧用户群体中的观点聚类效应。

2 相关工作

推荐系统的负面影响。推荐系统算法与多种不良社会现象有关，包括观点极化、过滤气泡和回音室。Santos 等人（2021）的研究表明，在高度相似的节点之间进行链接推荐，会导致加剧观点极化的网络拓扑。Ziegler 等人（2005）的研究提出了一种方法，用于平衡推荐列表中的多样性与个性化，从而能够探索用户兴趣的完整范围，并证明这有助于提升用户满意度。同样，Cheng 等人（2017）；Zhang 等人（2023）；Zhang & Hurley（2008）提出了将多样化目标纳入推荐流程的形式化优化框架，并提出了超越传统准确性度量、用于评估多样化质量的新指标。这些研究共同表明，在不严重损害准确性的前提下，可以提升多样化程度，有时甚至能提高准确性。然而，这些研究均以静态视角看待推荐算法，忽略了用户与推荐系统之间的动态互动。

意见动力学。意见动力学研究社交网络中相互作用的智能体之间，观点如何演变和传播 Proskurnikov & Tempo（2017）；Mei 等人（2022）；Altafini（2012）；Parsegov et al.（2017）；Friedkin & Johnsen（1990）。在我们的研究中，我们明确考虑网络对用户偏好的影响，并假设用户和创作者的偏好都会根据扩展版的 Friedkin–Johnsen模型动态演变——

地演变。该扩展模型纳入了多个主题 Parsegov 等人（2017），其中观点在相互连接的用户、推荐内容以及每位用户自身先入观念的共同影响下演变。

链接推荐。 有一系列研究分析了当观点遵循 Friedkin-Johnsen 动力学时，链接推荐对观点的影响 Wang & Kleinberg (2023); Zhu et al. (2021); R´acz & Rigobon (2023); K¨uhne et al. (2025); Chitra & Musco (2020)。具体而言，Wang & Kleinberg (2023) 研究了在社交网络中增加链接与网络冲突程度之间的关系。R´acz & Rigobon (2023) 研究了中央规划者如何改变社交网络的结构以减少极化。Zhu et al. (2021); K¨uhne et al. (2025); Chitra & Musco (2020) 的研究则探讨了如何设计链接推荐，在满足一定预算约束的前提下，同时将观点极化和意见分歧降至最低。

表演性预测。 表演性预测支持那些会影响其旨在预测结果的决策 Perdomo et al. (2020)。推荐系统正是如此，其目标是预测用户感兴趣的内容。推荐系统的设计与评估通常采用监督式机器学习视角，将观众偏好和内容目录视为静态的。然而在实践中，推荐系统会与观看者和内容创作者互动，并塑造双方的行为。这种互动在系统及其用户之间形成了反馈循环 Li et al. (2024)。近期一系列研究通过对推荐系统—用户交互进行建模，明确呈现这一反馈循环，并研究用户的观点如何在推荐内容的影响下演变 Dean & Morgenstern (2022); Yao et al. (2024); Rossi et al. (2022); Davidson & Ye (2025); Sprenger et al. (2024); Lin et al. (2024); Dean et al. (2024a); Chandrasekaran et al. (2024)。另一方面，Ben-Porat & Tennenholtz (2018); Hron et al. (2023); Jagadeesan et al. (2023); Eilat & Rosenfeld (2023); Yao et al. (2023) 等研究关注创作者的动态适应，同时将用户视为静态的。Dean et al. (2024b) 的立场论文提出了一个统一框架，将用户—创作者—推荐系统交互视为一个动力系统。Lin 等人（2024）采用基于模型的方法，并表明此类动力学会导致观点极化，而标准的促进多样性的策略不足以缓解这一现象。与 Lin 等人（2024）不同，我们考虑嵌入社交网络中的用户，他们不仅受到创作者推荐内容的影响，也会受到其他互联用户分享内容的影响。我们证明，在这种情境下，平衡内容多样性与个性化能够抑制观点聚类和极化。
为更好地定位本文，附录 G 节中的表格对相关工作以及我们与之的比较进行了示意性总结。

3 问题设定

我们考虑这样一种设定：用户通过推荐系统与内容创作者进行双向互动。与以往研究 Davidson & Ye（2025）；Rossi 等人（2022）类似，我们将观点视为影响用户偏好的驱动因素。形式化地，我们考虑两组智能体（建模为动力系统），它们在每个时间步 t围绕 n 个不同主题进行互动：

- **用户：** $\mathcal{U}^t = \{u_0^t, u_1^t, ..., u_{N-1}^t\}$，其中 $u_i^t \in [-1,1]^n$ 表示用户 i 在时间 t的观点。$\boldsymbol{u}_i^t$ 的第 k 个条目表示用户 i 在时间 t对项目 k 的观点。我们将时间 t 的全局用户观点向量定义为 $\mathbf{u}^t = \left[(u_0^t)^\top \quad \dots (u_{N-1}^t)^\top\right]^\top$。
- **内容创作者：** $\mathcal{C}^t = \{c_0^t, c_1^t, ..., c_{M-1}^t\}$，其中 $c_j^t \in [-1,1]^n$ 表示创作者 j 在时间 t的观点。c_j^t 的第 k个条目表示创作者 i 在时间 t对项目 k 的观点。我们将时间 t 的全局创作者观点向量定义为 $\mathbf{c}^t = \left[(c_0^t)^\top \quad \dots (c_{M-1}^t)^\top\right]^\top$。

在每个时间步 t，内容创作者会在 $\mathcal{C}^t$ 中发布反映其当前意见向量的内容材料。我们扩展了 Lin 等人（ 2024 ）提出的框架，并明确纳入社交网络对意见演化和整体用户行为趋势的影响。具体而言，我们假设所有智能体之间存在闭环交互，从而形成一个动态反馈系统，其中：（1）推荐内容会随着时间推移影响用户意见；（2）内容创作者会根据受众隐式反馈调整其内容策略；（3）用户生活在社交网络中，并随着时间推移相互影响。尽管用户与创作者之间存在相互影响，但这两类智能体的区别在于其交互的性质：

- **用户间交互：**通过社交网络进行。也就是说，如果两名用户通过其社交网络直接连接，他们就会相互影响。
- **创作者—用户互动：**通过推荐系统进行。具体而言，推荐系统会向每位用户展示部分内容创作者。反过来，内容创作者只能收到通过推荐系统触达他们的用户所提供的反馈。

这些互动所产生的动力学建模如下：

$$\mathbf{u}^{t+1} = f(\mathbf{u}^t) + h^t(\mathbf{c}^t), \tag{1a}$$

$$\mathbf{c}^{t+1} = p^t(\mathbf{u}^t) + q(\mathbf{c}^t), \tag{1b}$$

$$c_j^t \sim \mathcal{R}(u_i^t), \qquad \forall i = 1, \ldots, N \quad j = 1, \ldots, M, \tag{1c}$$

其中，用户 i在时间 t是否与创作者 j 的内容互动 t，是从概率分布 $\mathcal{R}$ 中采样得到的，该分布由推荐系统在时间 t为用户 i指定的推荐所决定。函数关系 f、h、p、q 以及方程1中的定义，均由 Parsegov et al. (2017) 提出的多主题扩展Friedkin-Johnsen模型给出，并按照 Sprenger等（2024）所采用的相同方式，扩展纳入了推荐系统的影响。下文将详细讨论这些函数。关于该模型的完整讨论，请参阅附录A。

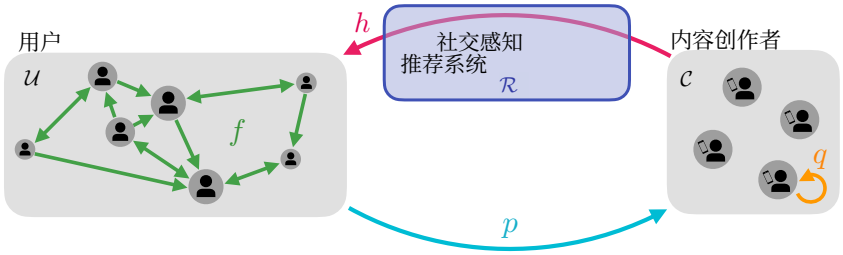

图1：方程1所述动态框架概览。用户 $\mathcal{U}$ 通过动力学 $f(\cdot)$相互影响，并通过 $h^t(\cdot)$在 $\mathcal{R}$的调节下受到内容创作者的影响。内容创作者具有内部意见动态 $q(\cdot)$，并通过 $p^t(\cdot)$受到用户的影响。

3.1 用户间交互

在我们的框架中，用户通过社交网络中的互动相互影响。

定义1（社交网络）。 设 $A \in \mathbb{R}^{N\times N}$ 为一个邻接矩阵，其中 $A_{ij} > 0$ 表示用户 j 以权重 A_{ij} 影响用户 i 。社交网络是一个有向加权图$\mathcal{G}$（$\mathcal{U}$、$\mathcal{E}$、A），其中每个节点 $i \in \mathcal{U}$ 对应一个用户个体，$\mathcal{E}$ 表示代表社交连接的边集。当且仅当用户 j 直接影响用户 i（即 $A_{ij} \neq 0$）时，边（j、i）$\in \mathcal{E}$ 存在。

根据定义1以及针对单一主题的 Friedkin & Johnsen（1990）模型，即 $n =$ 1，

$$f(\mathbf{u}^t) = (I_N - \Lambda)A\mathbf{u}^t + \Lambda\mathbf{u}^0, \tag{2}$$

其中，I_N是 N维单位矩阵，$A \in [0,1]^{N\times N}$是次随机矩阵，也是该社交网络的邻接矩阵。矩阵 Λ 是一个对角矩阵，其元素 $\lambda_i \in (0,1]$）表示用户对意见改变的阻力（“固执性”），而 u_i^0表示用户的 i 初始意见（“先入观念”）。假设用户具备一定程度的批判性思维，即 A 的对角线元素非零。我们将采用 Parsegov 等人（2017）对公式2的多议题版本，详见附录A。

我们注意到，非对称社会关系在具有“关注”动态的现代平台中十分常见，而这种表示方式能够自然地捕捉这些关系。具体来说，对于每个用户，我们都可以定义一个集合，其中包含通过其 d 跳社交网络对该用户产生影响的所有用户。参数 d 控制社会情境的广度：值越大，纳入的远距离连接就越多。

定义2 (d跳数影响者)。 对于图 $\mathcal{G}(\mathcal{U}, \mathcal{E}, A)$，用户 $i \in \mathcal{U}$ 的 d 跳影响者位于$_i(d) = \{j \in \mathcal{U} \mid \textit{dist}(j \to i) \leq d\}$，且 $i \in$ 位于 $\textit{in}_i(d)$。

3.2 创作者—用户互动

在我们的框架中，创作者和用户通过推荐系统相互影响。具体而言，推荐系统是一个关于内容创作者的概率分布：对于每个用户 i，$c_j^t \sim \mathcal{R}(u_i^t)$，该分布取决于每位用户当前的观点 u_i^t。也就是说，推荐系统会根据用户的偏好调整向其推荐内容的概率分布；本研究所探讨的具体推荐策略详情将在以下各节中介绍。[1]。

定义3。令 $\mathcal{F}_1^t, \ldots, \mathcal{F}_M^t$ 为时间 t时将 $\mathcal{U}$ 划分为若干子集所得到的不相交划分集合。用户划分 $\mathcal{F}_j^t$ 包含所有在时间 t消费创作者 j所创作内容的用户 i，即若在时间 t从 $\mathcal{R}(u_i^t)$ 中采样得到 c_j^t，则有 $i \in \mathcal{F}_j^t$。

这使我们能够定义内容创作者和用户如何相互影响。

内容创作者对用户的影响如下：

$$h^t(\mathbf{c}^t) = (I_N - \Lambda)B^t\mathbf{c}^t, \tag{3}$$

其中 $B^t \in [0,1]^{N\times M}$，且 B^t 满足 $[A\, B^t]\vec{1}_{N+M} = \vec{1}_N$，这与 Sprenger等（2024）中的设定类似。B^t 描述推荐对用户 i 意见的影响力，其中若 $i \in \mathcal{F}_j^t$ 在时间 t，则 $B_{ij}^t \neq 0$，否则为其他情况。也就是说，只有当用户消费创作者 j 的内容时，创作者才能在时间 t 直接影响用户的 i 观点。

与用户类似，我们假设创作者也具备一定程度的批判性思维。这可表示为：

$$q(\mathbf{c}^t) = (I_M - \Gamma)E\mathbf{c}^t + \Gamma\mathbf{c}^0, \tag{4}$$

其中，I_M是 M维单位矩阵，E，$\Gamma \in [0,1]^{M\times M}$是对角矩阵（创作者之间不存在相互影响），用于控制创作者观点的时间一致性，决定其先前立场的影响力。c_j^0 表示创作者的初始观点。

用户对内容创作者的影响如下：

$$p^t(\mathbf{u}^t) = (I_M - \Gamma)C^t\mathbf{u}^t, \tag{5}$$

其中，$C^t \in [0,1]^{M\times N}$，且 C^t 满足 $[E\, C^t]\vec{1}_{M+N} = \vec{1}_M$。$C^t$ 描述用户反馈对创作者 j 观点的影响力，其中，若 $i \in \mathcal{F}_j^t$ 在时间 t，则 $C_{ji}^t \neq 0$；否则为 $C_{ji} = 0$。也就是说，创作者 j 只会收到消费其内容的用户所提供的反馈。

3.3 推荐系统

推荐系统直接调节创作者与用户之间的交互，并间接调节用户与创作者之间的交互。推荐系统的目标是对内容进行排序并呈现给用户，以最大限度地提高用户参与度。根据确认偏误理论（Nickerson，1998），推荐与用户现有观点完全吻合的内容即可实现这一目标。然而，研究表明，这种贪心方法会导致观点极化和聚类行为（Del Vicario等（2017））。因此，我们研究如何设计一种推荐系统，使其（a）最大限度地提高用户满意度，同时（b）在全局范围内减少聚类效应。为此，我们让推荐系统明确考虑社交网络的存在。接下来，我们将对满意度和聚类作出形式化定义。

满意度。满意度通过衡量用户的观点与所选内容在整个时间序列 $\{0, \ldots, T\}$ 中的累积距离来量化。鉴于用户的参与度受确认偏误 Nickerson (1998) 驱动，推荐系统将推荐内容以最大化用户满意度，定义如下。

定义4 (用户满意度)。用户 i（观点为 $u_i^T \in \mathcal{U}^T$）对创作者 j（观点为 $c_j^T \in \mathcal{C}^T$）在时间 T 的满意度为：

$$sat(u_i^T, c_j) = \begin{cases} -\dfrac{1}{T}\sum_{t=0}^{T-1} \|u_i^t - c_j^t\|_2, & \text{if } c_j^t \sim \mathcal{R}_i^t, \\ 0, & \text{otherwise.} \end{cases} \tag{6}$$

[1]一种常见的概率分布选择，通常是最大化确认偏误的效用函数的 Softmax（Nickerson，1998）。更多详情请参见 Anas（1983）；Chee 等（2024）；Kalimeris 等（2021）；Hazrati 和 Ricci（2022）及其中的参考文献。

定义4形式化地说明，用户会更多地参与与自身观点密切相关的内容。在全局范围内，推荐系统希望最大化全局满意度，定义如下。

定义5 (全局满意度)。 设 $\mathcal{U}^t$ 为时间 t的 N 用户集合，则时间 t的全局满意度为：

$$sat(\mathcal{U}^t) = \frac{1}{N}\sum_{i=0}^{N-1} sat(u_i^t). \tag{7}$$

聚类。 观点聚类通过每个用户在其所属簇中的轮廓系数来量化（根据意见向量通过 k-均值计算）。[2] 较高的轮廓系数表示用户的观点与其所属簇匹配良好，而与相邻簇的匹配较差。如果用户能够被清晰地划分到某个簇中，因而具有较高的观点轮廓系数，那么观点分布格局就是聚类化的。

定义6 (用户轮廓系数)。 给定一个选项 $u_i^t \in \mathcal{F}_i$，轮廓系数定义如下：

$$s(u_i^t) = \frac{b(u_i^t) - a(u_i^t)}{\max\{a(u_i^t), b(u_i^t)\}} \in [-1, 1], \tag{8}$$

其中 $a(u_i^t) = \frac{1}{|\mathcal{F}_i|-1}\sum_{u_j^t \in \mathcal{F}_i,\ j\neq i} ||u_i^t - u_j^t||_2$ 为簇内距离的平均值，而 $b(u_i^t) = \min_{l\neq i} \frac{1}{|\mathcal{F}_l|}\sum_{\boldsymbol{u}_k^t \in \mathcal{F}_l} ||u_i^t - u_k^t||_2$ 为簇间距离平均值的最小值。

定义7（全局聚类）。集合 $\mathcal{U}^t$ 的全局观点聚类定义为

$$cl(\mathcal{U}^t) = \frac{1}{N}\sum_{i=0}^{N-1} s(u_i^t). \tag{9}$$

接下来，我们将介绍一种推荐系统设计，该设计通过考虑社交网络动态，在满意度与聚类之间实现平衡。

4 推荐系统设计

本节将介绍我们具备社交感知能力的推荐系统设计。与在线平台采用的个性化信息流机制中的常见做法一致，我们考虑一种两阶段算法策选策略，以确定向每位用户展示哪些可用内容。每个时间步 t，该推荐系统：

（i）为每位用户计算参考推荐 $r_i^t \in \mathbb{R}^n$ i，该推荐取决于其观点 u_i^t，即 $r_i^t := r(u_i^t)$。（ii）通过向用户展示排名前 k 的推荐内容，即 k 与该参考点最接近的内容项，提供这些推荐，采用 k近邻搜索：

$$\mathcal{R}(u_i^t) = \left\{ c_j^t \;\middle|\; \|c_j^t - r_i^t\|_2 \in k\text{-top}\min_j \{\|c_j^t - r_i^t\|_2\}_{j=1}^M \right\}. \tag{10}$$

每位用户 i 在每个时间步 t，都会从 $\mathcal{R}(u_i^t)$ 中采样一个元素（内容），即根据温度参数为 δ^{-1} 的 Softmax 采样 $c_j^t \sim \mathcal{R}(u_i^t)$。接下来，我们将给出一项理论结果，阐明 $r(u_i^t)$ 的选择如何影响用户满意度和聚类，并提出一种设计方案。该方案通过模仿社交网络的结构，可证明能在这两项指标之间实现最佳平衡。

4.1 满意度与聚类的推荐策略

通过研究1中的反馈机制动力学，可以深入了解如何设计推荐系统，在提升用户满意度的同时避免聚类。考虑以下动力学

[2]按照惯例，通过对不同的 k 值运行 k-均值算法，并选择平均轮廓系数最高的值，来确定最佳簇数。

在没有推荐系统介入且用户分区保持静态的情况下，方程1中的情形。在这种情况下，方程1变为：

$$\mathbf{u}^{t+1} = (I_N - \Lambda)A\mathbf{u}^t + \Lambda\mathbf{u}^0 + (I_N - \Lambda)B\mathbf{c}^t, \tag{11a}$$

$$\mathbf{c}^{t+1} = (I_M - \Gamma)E\mathbf{c}^t + \Gamma\mathbf{c}^0 + (I_M - \Gamma)C\mathbf{u}^t, \tag{11b}$$

其中 B 和 C 是静态的，因为用户分区是静态的。也就是说，用户会随着时间推移与同一位内容创作者互动。接下来，我们将探讨动态组件（社交网络 A、创作者的影响力 B等）对用户意见演变的影响。

我们还研究了不同的推荐策略如何影响整体动态行为，并强调推荐系统和社交连接在该框架中的关键作用。为此，我们考虑采用方程10中的推荐策略，并令 $k = 1$。这意味着推荐系统变为确定性映射，即 $c_j^t = R(u_i^t)$。请注意，这种简化使我们能够跳过根据推荐随机采样内容的过程——这一假设仅用于理论结果；模拟则采用完整的随机设置。

4.1.1 社会互动减轻推荐的影响

定理1。 对于具有方程*11*所示动力学的系统，用户的意见会达到稳态，即 $\exists \mathbf{u}^* \in \mathbb{R}^N$，使得 $\lim_{t\to\infty} \mathbf{u}^t = \mathbf{u}^*$。此外，社交网络（$A$）对每位用户 $i \in \{1, \ldots, N\}$的影响，即 $\sum_j A_{i,\ j}$，以及推荐内容（即 B_i）对$\mathbf{u}^*$的影响是相辅相成的：增加其中一项会降低另一项。*</output>*

证明见 F.2节。直观而言，定理1指出，当用户长期持续与同一位创作者互动时，他们会逐渐接近该创作者的观点。反过来，创作者会适应其固定受众，直至达到均衡。这种情况的程度取决于用户和创作者的固执性（分别由 Λ和 Γ 表示），以及社交连接的强度（由 A 表示）。该定理表明，社交网络与推荐内容会对稳态下用户的观点产生两种相反的作用力。

我们注意到，社交网络通过在用户连接中传播观点，推动了动态分区。然而，即使是同一分区内的连接，也能通过间接的网络效应缓解静态分配的形成。同一分区内的用户往往仍与其他簇中的用户保持路径连接，从而使观点得以跨越分区边界扩散。

4.1.2 最大化满意度的推荐系统会增加聚类

推荐系统的主要目标是最大化用户的参与度。因此，考虑能够最大化用户满意度的推荐系统设计是很自然的。贪心推荐系统仅通过利用确认偏误来最大化满意度（Nickerson (1998)）。也就是说，推荐系统会提供与用户观点最为一致的内容创作者，即

$$R(u_i^t) = \text{argmin}_{c_j}(||c_j^t - u_i^t||_2). \tag{12}$$

Thi根据定义5中用户满意度的定义，s策略实现了最大满意度 .

引理1。考虑具有方程*1*所述动力学的系统。设 A为对角矩阵，且创作者是固执的，即 $\Gamma = I_M$。那么，方程*12*中的贪心推荐系统会诱导出静态用户分区 $\mathcal{F}_1$、...、 $\mathcal{F}_M$，并且根据定理*1*，用户的意见达到稳态。此外，对于任意用户 $i \in \mathcal{F}_j$，所有意见都会趋近于所推荐创作者的内容，即 $||u_i^t - c_j^t||_2$ 随时间单调递减。

证明见 F.2节。直观而言，通过将用户静态分配给创作者，用户会陷入过滤气泡，持续参与那些提供与其观点高度契合内容的创作者的互动。当用户缺乏社会互动来抵消推荐系统的影响时，这种效应会加剧。根据定理1，静态用户—创作者映射会导致形成一种促进观点聚类的均衡。此外，用户的观点越接近创作者的观点，他们离开气泡的可能性就越小。关键在于，当社交网络效应不足以抵消推荐系统的同质化影响时，就会出现全局极化。社交连接与推荐影响的相对强度决定了这一临界点，即聚类效应开始占据主导的时刻。我们在实验部分通过实证展示了这一现象。

4.1.3 降低聚类的推荐系统会降低满意度

我们已经表明，在缺乏社会互动的情况下，仅以满意度为目标会促使观点围绕创作者聚类。为了打破将每位用户静态分配给创作者的做法，推荐系统必须摆脱互动最大化，转而促进内容多样性。

推论1。令方程 11 $\forall i$、j 中的 $c_j^t = R(u_i^t)$ 由非贪心推荐系统产生，即 $R(u_i^t) \neq \min_j(||c_j^t - u_i^t||_2)$。则方程7中的用户满意度不是最优的。

证明。该证明直接由方程7得出。也就是说，对于某个 $j \in 0,...,M-1$，若 $c_k^t = R(u_i^t)$ 且 $||u_i^t - c_k^t||_2 > \min_j ||u_i^t - c_j^t||_2$，则会导致用户 i 的满意度降低。 □

结合引理1，该论述推动了在最大化用户满意度与抑制观点聚类之间寻求权衡。

4.2 社交感知推荐系统模拟社交网络

鉴于社交连接能够自然地缓解聚类，我们提出了一种明确利用网络结构的推荐策略。我们的方法并非仅针对个体偏好进行优化，而是以社交感知的方式扩展了贪心推荐系统。也就是说，推荐系统除了考虑用户的个体观点外，还会纳入社交邻域内用户的观点。为此，我们将利用定义2中的 d-跳影响者 概念。具体而言，我们设计了一种通过利用每位用户的 d 跳影响者的平均观点来模拟社会影响的推荐系统，并将其作为推荐系统的推荐参考值。

定义8 (d跳数的具备社交感知能力的推荐系统)。设 $in_i(d)$ 为用户 i 的 d 跳影响者。d 跳的具有社会意识的推荐系统生成的推荐参考值如下：

$$r(u_i^t) = \frac{1}{|in_i(d)|} \sum_{j \in in_i(d)} u_j^t. \tag{13}$$

设计参数 d 控制个性化与多样化之间的权衡：$d = 0$对应引理1中的贪心策略，而较大的值则会纳入更广泛的社会影响。

如果推荐系统提供 d 跳邻域的平均观点，那么用户的观点就会被拉向其邻域的平均观点，其中也包括来自其他簇的邻居。这种机制会缩小簇之间的差异。增大 d可以提升内容多样性，但会降低用户满意度，因为推荐内容会进一步偏离个体偏好。在下一节中，我们将通过实证分析这种权衡，并找出能够最大限度减少全局聚类、同时维持用户满意度的参数值。

5 实验

我们使用方程5和方程7中的满意度与聚类指标来评估推荐系统的性能。首先，我们通过一项实验研究推荐系统与合成社交网络之间的闭环交互。随后，我们在 McAuley & Leskovec（2012）的 Facebook-ego数据集上展示研究结果，该数据集包含由4039名用户组成的社交网络。在本节中，用于控制用户选择的温度参数设为 $\delta^{-1} = 0.5$。下面介绍我们的主要发现。

5.1 合成数据的实验设置 ASET

我们考虑一个包含 $N = 600$ 个用户和 $M = 50$ 个内容创作者的网络，用户平均入度为 11。方程1中支配用户-创作者和创作者-用户动态的所有交互参数详见 B.1 节。为便于表示，我们将意见维度设为$n = 2$，并将所有用户和创作者的意见初始化为 $[-1, 1]^n$ 内的均匀随机值。社交网络拓扑是随机生成的，用户之间存在边的概率会随着他们意见距离的增大而降低。因此，意见更接近的用户更有可能相互连接。这种设置符合社交网络中的同质性原则，从而使相似用户之间有更多接触机会（McPherson 等人（2001））。具体的连接概率函数详见 B.2 节。

5.2 合成数据集上的实验结果

推荐系统采用 top-k 推荐策略，且 $k = 5$。C 节分析了在以下设置中，不同 k 以及方程1中变化的交互参数对所有性能指标的影响。

5.2.1 不同推荐系统策略下的聚类与满意度

我们研究了三种不同的推荐系统策略：(i) 推荐系统仅优化用户参与度（带有 $d = 0$的贪心推荐系统），(ii) 推荐系统仅考虑观点多样性（具有社会意识的推荐系统，带有 $d = 6$，多样化程度较高），以及 (iii) 在满意度与多样性之间进行平衡的混合推荐系统（带有$d = 3$的具有社会意识的推荐系统，定位程度适中）。策略 (i) 仅考虑个性化推荐，策略 (ii) 通过考虑广泛的网络效应来强调社会互动，而策略 (iii) 则寻求在用户满意度与内容多样性之间取得平衡。
图2展示了在三种所提出的推荐系统策略下，用户和创作者观点分布格局在不同时间步的演变过程。通过 k-means 聚类获得的用户观点簇以椭球体表示，其轴对应于沿主成分方向的两倍标准差。椭球体的透明度随全局聚类程度的增加而降低。全局聚类值低于 0.5 的簇将被省略，因为它们缺乏明确的结构。图2的最后一列展示了负的全局聚类程度和用户满意度随时间的变化。理想情况下，希望两条曲线都能随时间上升。我们注意到，贪心推荐系统 (i) 会导致围绕创作者形成明显的用户簇，并且这种极化效应会在更长的时间范围内不断增强。具有社会意识的推荐系统 (ii) 降低了聚类程度，但代价是用户满意度显著下降。混合推荐系统 (iii) 在维持高满意度的同时，有效缓解了聚类效应，在两个目标之间实现了平衡。

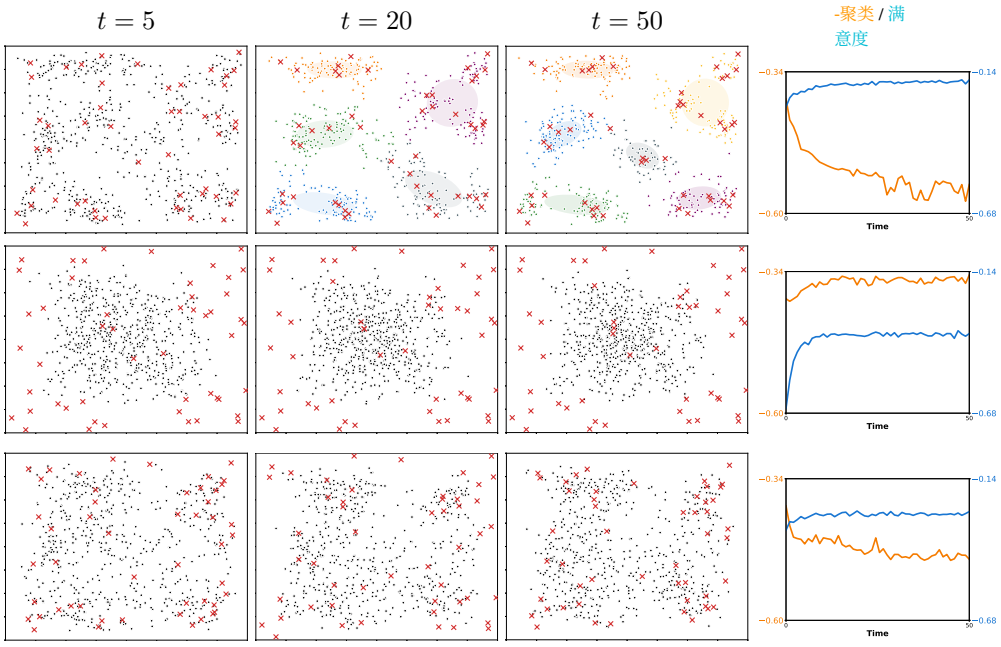

图2：采用局部区域模拟的意见环境快照 (i) $d = 0$，第一行，(ii) $d = 6$，第二行 (iii) $d = 3$，第三行。× 表示创作者，● 分别表示用户。

图3展示了在 $t = 50$ 和 $t = 500$处，负向全局观点聚类和用户满意度随局部化参数 d变化的情况，以及它们的方差[3]。随着 d 增加，聚类程度和满意度均有所下降。在 $d = 3$处出现一个最佳点：聚类程度急剧下降，同时满意度仍然较高。

[3]方差按照方程7和方程9，对用户进行计算。

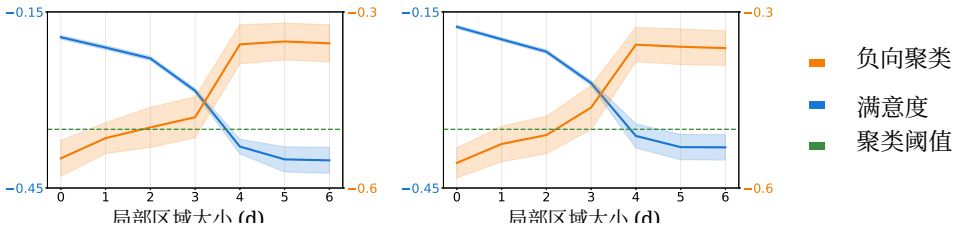

(a) 经过 50 个时间步 (b) 经过 500 个时间步

图3： d变化后全局聚类和全局用户满意度的变化曲线：(a) 50 个时间步后；(b) 500 个时间步后。聚类阈值设为 -0.5，此时簇已无法区分。

5.3 真实数据集实验设置

EGO-FACEBOOK数据集包含由4039名用户构成的社交网络。由此得到的社交图$\mathcal{G}(\mathcal{U},\ \mathcal{E},\ W)$的平均度为45，且为双向图，即当且仅当$(j,\ i) \in \mathcal{E}$时，$(i,\ j) \in \mathcal{E}$。我们考虑 $M = 120$具有随机初始观点的内容创作者，并将观点维度设为 $n = 3$。方程1中所有用于控制用户-创作者和创作者-用户动态的交互参数详见D.1节。为了生成能反映社交网络固有同质性结构的初始用户观点，我们采用Luxburg（2004）的谱聚类来识别网络社区，然后为同一社区中的用户分配相似的观点。详情见D.2节。

5.4 真实数据集实验结果

该推荐系统采用带有 $k = 5$的前k 推荐策略。图4展示了经过 $t = 20$ 个时间步后以下情况下的用户观点分布：(i) 采用 $d = 0$ 的贪心推荐系统，以及(ii) 采用 $d = 3$的混合推荐系统。为便于说明，我们省略了左侧三维图中的创作者意见，并且在展示投影到 xy平面、 xz平面和 yz平面上的图中，用户意见和创作者意见分别仅显示每四个中的一个。

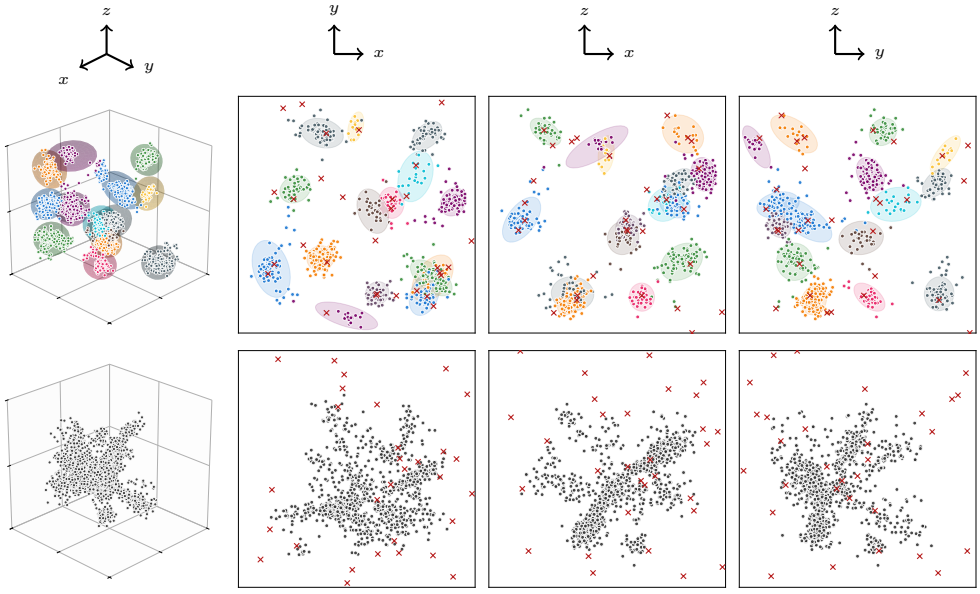

图4：快照，展示意见环境在采用局部区域的情况下模拟 $t = 20$ 个时间步后的状态：(i) $d = 0$，第一行；(ii) $d = 3$，第二行。 ×表示创作者， • 分别表示用户。

参考文献

Claudio Altafini。具有对抗性交互的网络中的共识问题。*IEEE Transac-tions on Automatic Control*，58(4):935–946，2012。

Alex Anas。离散选择理论、信息论与多项 logit 和引力模型。《交通研究 *B*：方法论》，17：13–23，1983年2月。

Omer Ben-Porat 和 Moshe Tennenholtz。针对策略性内容提供商的推荐系统博弈论方法。载于 S. Bengio、H. Wallach、H. Larochelle、K. Grauman、N. Cesa-Bianchi 和 R. Garnett（编），神经信息处理系统进展，第31卷，第1–11页。Curran Associates, Inc.，2018年。

Sanjay Chandrasekaran、Giulia De Pasquale、Giuseppe Belgioioso 和 Florian D¨orfler。通过在线反馈优化实现网络感知推荐系统，2024年。

Jerry Chee、Shankar Kalyanaraman、Sindhu Kiranmai Ernala、Udi Weinsberg、Sarah Dean 和 Stratis Ioannidis。用户偏好动态下推荐系统中的危害缓解。载于第*30*届 *ACM SIGKDD* 知识发现与数据挖掘大会论文集，KDD '24，第255–265页。ACM，2024年。

Peizhe Cheng、Shuaiqiang Wang、Jun Ma、Jiankai Sun 和 Hui Xiong。学习推荐准确且多样化的项目。载于《第*26*届国际万维网大会论文集》，WWW '17，第 183–192 页，日内瓦共和国和州，CHE，2017 年。国际万维网大会指导委员会。

Uthsav Chitra 和 Christopher Musco。分析过滤气泡对社交网络极化的影响。载于《第*13*届国际网络搜索与数据挖掘大会论文集》，WSDM '20，第 115–123 页，美国纽约州纽约，2020 年。计算机协会。ISBN 9781450368223。doi：10.1145/3336191.3371825。网址：https: //doi.org/10.1145/3336191.3371825。

Federico Cinus、Marco Minici、Corrado Monti 和 Francesco Bonchi。人际推荐系统对回音室和极化的影响。第*16*届 *AAAI* 国际网络与社交媒体大会（*ICWSM 2022*），第 90–101 页，2022 年。

Paul Covington、Jay Adams 和 Emre Sargin。用于 YouTube 推荐的深度神经网络。载于第*10*届 *ACM* 推荐系统大会论文集，RecSys '16，第 191–198 页，纽约，纽约州，美国，2016年。ACM。

Ella C. Davidson 和 Mengbin Ye。社交媒体推荐系统与用户观点之间的闭环动态建模。*arXiv:2507.19792*，第 1–27 页，2025年。

Sarah Dean 和 Jamie Morgenstern。个性化推荐下的偏好动态。载于第*23*届 *ACM*经济学与计算会议论文集，第 795–816 页，2022年。

Sarah Dean、Evan Dong、Meena Jagadeesan 和 Liu Leqi。探究人工智能与用户如何相互塑造：数学模型的作用。机器学习研究汇刊，第 1–25 页，2024a。

Sarah Dean、Evan Dong、Meena Jagadeesan 和 Liu Leqi。作为动力系统的推荐系统：与观看者和创作者的互动。载于推荐生态系统研讨会：建模、优化与激励设计，2024b。

Michela Del Vicario、Antonio Scala、Guido Caldarelli、H Eugene Stanley 和 Walter Quattrocioc-chi。建模确认偏误与极化。《科学报告》，7(1):40391，2017 年。

Itay Eilat 和 Nir Rosenfeld。表演性推荐：通过策略性激励实现内容多样化。载于国际机器学习会议，2023 年。网址 https://api. semanticscholar.org/CorpusID:256697126。

Noah E Friedkin 和 Eugene C Johnsen。《社会影响与意见》。《数学社会学杂志》，15(3-4):193–206，1990 年。

Carlos A . 戈麦斯 - 乌里韦和 Neil Hunt . Netflix 推荐系统：算法 ，商业价值与创新。*ACM* 信息系统管理汇刊，6(4):1–19，2016。Taha Hassan。社交推荐系统中的信任与可信度。载于*2019* 年万维网大会附属论文集，WWW '19，第 529–532 页，美国纽约州纽约市，2019。ACM。Naieme Hazrati 和 Francesco Ricci。推荐系统对用户选择分布演化的影响。《信息处理与管理》，59:102766，2022 年 01 月。Jiri Hron、Karl Krauth、Michael I Jordan、Niki Kilbertus 和 Sarah Dean。算法策展平台中的内容创作者激励建模。载于国际学习表征会议，2023。Meena Jagadeesan、Nikhil Garg 和 Jacob Steinhardt。推荐系统中的供给侧均衡。《神经信息处理系统进展》，36:14597–14608，2023。Dimitris Kalimeris、Smriti Bhagat、Shankar Kalyanaraman 和 Udi Weinsberg。推荐系统中的偏好放大。载于第 *27* 届 *ACM SIGKDD* 知识发现与数据挖掘会议论文集，KDD '21，第 805–815 页。ACM，2021。Marino K¨uhne、Panagiotis D. Grontas、Giulia De Pasquale、Giuseppe Belgioioso、Florian Dorfler 和 John Lygeros。通过基于超梯度的推荐系统设计优化社交网络干预。载于第四十二届国际机器学习会议，2025。网址 https://openreview.net/forum?id=Q4tpr9bnXU。Nicolas Lanzetti、Florian D¨orfler 和 Nicol`o Pagan。推荐系统对意见动力学的影响：微观效应与宏观效应。载于*2023* 年第 *62* 届 *IEEE* 决策与控制会议（*CDC*），第 4824–4829 页，2023。Yang Li、Kangbo Liu、Ranjan Satapathy、Suhang Wang 和 Erik Cambria。推荐系统的最新发展：综述 [评论文章]。《IEEE 计算智能杂志》，19(2):78–95，2024年。Tao Lin、Kun Jin、Andrew Estornell、Xiaoying Zhang、Yiling Chen 和 Yang Liu。具有双重影响的推荐系统中的用户—创作者特征极化。载于第 *38* 届国际神经信息处理系统会议论文集，NeurIPS '24，美国纽约州雷德胡克，2024。G. Linden、B. Smith 和 J. York。Amazon.com 推荐：基于项目到项目的协同过滤。《IEEE《互联网计算》》，7(1):76–80，2003。Ulrike Luxburg。谱聚类教程。《统计学与计算》，17:395–416，2004 年 01 月。doi: 10.1007/s11222-007-9033-z。Hao Ma、Haixuan Yang、Michael R Lyu 和 Irwin King。SoRec：使用概率矩阵分解进行社交推荐。载于第 *17* 届 *ACM* 信息与知识管理会议论文集，第 931–940 页，2008。Julian McAuley 和 Jure Leskovec。学习发现自我中心网络中的社交圈。载于第 *26* 届国际神经信息处理系统会议论文集——第 *1* 卷，NIPS'12，第 539–547 页，美国纽约州雷德胡克，2012。Curran Associates Inc。Miller McPherson、Lynn Smith-Lovin 和 James M. Cook。同类相吸：社交网络中的同质性。《社会学年度评论》，27:415–444，2001。ISSN 03600572，15452115。网址 http://www.jstor.org/stable/2678628。Wenjun Mei、Francesco Bullo、Ge Chen、Julien M. Hendrickx 和 Florian D¨orfler。意见动力学的微观基础：加权中位数机制的丰富后果。《物理评论研究》，4:023213，2022 年 6 月。Raymond Nickerson。确认偏误：以多种形式普遍存在的现象。《普通心理学评论》，2:175–220，1998 年 06 月。

S. Parsegov、Anton Proskurnikov、Roberto Tempo 和 Noah Friedkin。社交网络中意见动力学的新型多维模型。《IEEE 自动控制汇刊》，62:2270–2285，052017。

JuanPerdomo、Tijana Zrnic、Celestine Mendler-D¨unner 和 Moritz Hardt。表演性预测。载于国际机器学习会议，第 7599–7609 页。PMLR，2020。

Anton V. Proskurnikov 和 Roberto Tempo。《动态社交网络建模与分析教程》第一部分。*Annual Reviews in Control*，43：65–79，2017。ISSN 1367-5788。

ShainaRaza、Mizanur Rahman、SafiullahKamawal、Armin Toroghi、AnanyaRaval、Farshad Navah 和 Amirmohammad Kazemeini。推荐系统综述：从理论迈向实践。*arXiv:2407.13699*，第 1–66 页，2025。

Wilbert Samuel Rossi、Jan Willem Polderman 和 Paolo Frasca。意见形成与个性化推荐之间的闭环。*IEEE* 网络系统控制汇刊，9(3)：1092–1103，2022。

Miklos Z. R´acz 和 Daniel E. Rigobon。迈向共识：通过扰动社交网络降低极化。*IEEE* 网络科学与工程汇刊，10(6):3450–3464，2023。doi: 10.1109/TNSE.2023.3262970。

Fernando Santos、Yphtach Lelkes 和 Simon A. Levin。在线社交网络中的链接推荐算法与极化动力学。美国国家科学院院刊，50(118)，2021年。

ManelSlokom、Savvina Danil 和Laura Hollink。如何让任何个性化推荐系统实现多样化？信息检索进展。*ECIR 2025*，15575:1–17，2025年。

Ben Sprenger、Giulia De Pasquale、Raffaele Soloperto、John Lygeros 和 Florian D¨orfler。社交网络中推荐系统的控制策略。*IEEE* 控制系统快报，8:634– 639，2024年。

Ruilong Su、Li'Ang Yin、Kailong Chen 和 Yong Yu。《面向多样化 top-n 推荐的集合导向个性化排序》。载于第七届 *ACM* 推荐系统会议论文集，RecSys '13，第 415–418 页，纽约，纽约州，美国，2013 年。ACM。

Yanbang Wang 和 Jon Kleinberg。《在线社交链接推荐中相关性与冲突之间的关系》。载于 A. Oh、T. Naumann、A. Globerson、K. Saenko、M. Hardt 和 S. Levine（编），神经信息处理系统进展，第 36 卷，第 36708–36725 页。Curran Associates, Inc.，2023 年。网址 https://proceedings.neurips.cc/paper_files/paper/2023/file/73d6c3e4b214deebbbf8256e26d2cf45-Paper-Conference.pdf。

Xiwang Yang、Yang Guo、Yong Liu 和 Harald Steck。《基于协同过滤的社交推荐系统综述》。*Computer communications*，41：1–10，2014年。Fan Yao、Chuanhao Li、Denis Nekipelov、Hongning Wang 和 Haifeng Xu。《在竞争内容创作者的情况下，top-k推荐有多糟糕？》。载于国际机器学习会议，第39674–39701页。PMLR，2023年。Fan Yao、Yiming Liao、Mingzhe Wu、Chuanhao Li、Yan Zhu、James Yang、Jingzhou Liu、Qifan Wang、Haifeng Xu 和 Hongning Wang。《竞争内容创作者环境下推荐系统的用户福利优化》。载于第*30*届*ACM SIGKDD*知识发现与数据挖掘会议论文集，第3874–3885页，2024年。Mi Zhang 和 Neil Hurley。《避免单调性：提升推荐列表的多样性》。载于*2008*年*ACM*推荐系统会议论文集，RecSys '08，第123–130页，美国纽约州纽约，2008年。ACM。Xiaoying Zhang、Hongning Wang 和 Hang Li。《用于多样化推荐的解耦表示》。载于第十六届*ACM*网络搜索与数据挖掘国际会议论文集，WSDM '23，第490–498页，美国纽约州纽约，2023年。ACM。

Liwang Zhu、Qi Bao 和 Zhongzhi Zhang。《通过链接推荐最小化社交网络中的极化与意见分歧》。载于 M. Ranzato、A. Beygelz- imer、Y. Dauphin、P.S. Liang 和 J. Wortman Vaughan（编），神经信息处理系统进展，第34卷，第2072–2084页。Curran Associates, Inc.，2021年。网址 https://proceedings.neurips.cc/paper_files/paper/2021/file/101951fe7ebe7bd8c77d14f75746b4bc-Paper.pdf。

Cai-Nicolas Ziegler、Sean M. McNee、Joseph A. Konstan 和 Georg Lausen。通过主题多样化改进推荐列表。载于第*14*届万维网国际会议论文集，WWW '05，第22–32页，美国纽约州纽约，2005年。ACM。

多主题 FRIEDKIN-JOHNSEN 模型

多主题 FJ模型 Parsegov 等人（2017）将方程 2 中的经典标量模型扩展到每个用户同时对多个主题持有观点的情形。令 $u_i^t \in \mathbb{R}^n$ 表示用户 i 在时间 t的观点向量，其中每个分量对应一个不同主题。将所有 N用户的观点堆叠成一个向量 $\mathbf{u} \in \mathbb{R}^{Nn}$后，意见更新规则可写为

$$f(\mathbf{u}^t) = ((I_N - \Lambda)\hat{A} \otimes C)\mathbf{u}^t + (\Lambda \otimes I_n)\mathbf{u}^0, \tag{14}$$

其中，$\hat{A} \in \mathbb{R}^{N\times N}$ 是行随机影响矩阵，用于描述网络中的人际影响； $\Lambda \in \mathbb{R}^{N\times N}$ 是对角易感性矩阵，用于刻画每种影响对自身先入观念 $u^0 \in \mathbb{R}^{Nn}$ 相对于社会影响的依附程度； $\otimes$表示克罗内克积。矩阵 C 是不同主题之间的相关矩阵。我们考虑主题彼此不相关的情形，因此令 $C = I_n$。在这种特殊情况下，模型简化为

$$f(\mathbf{u}^t) = ((I_N - \Lambda)\hat{A} \otimes I_n)\mathbf{u}^t + (\Lambda \otimes I_n)\mathbf{u}^0. \tag{15}$$

B 合成数据集的环境变量

B.1 用户-创作者动力学的参数

方程1中的动力学参数从均匀分布中独立采样，其上下界如表格1所示。

表格1：均匀分布采样的模拟参数

参数	**下界**	**上界**
用户参数		
用户固执性 Λ_{i}	0.0	0.5
用户自我影响 A_{ii}	0.5	0.8
推荐者影响 B_{ij}	0.2	0.8
邻居影响 A_{ij}	0.025	0.05
创作者参数		
创作者固执性 Γ_{j}	0.0	0.5
创作者自我影响 E_{j}	0.5	0.8
用户-创作者影响力 C_{j}	0.2	0.8

用户-创作者影响力在创作者 j 的受众集合中均匀分布；具体而言，对于受众集合为 $\mathcal{F}_j$ 的创作者 j，每个用户 $i \in \mathcal{F}_j$ 施加的影响为 $C_{ji} = C_j/|\mathcal{F}_j|$。用户 i 所受到的总体社会影响由所有邻居施加的影响之和决定。每个用户恰好受到一位创作者的影响。因此，参考 A 节中的 FJ模型，我们得到以下随机约束：用户的约束为 $A_{ii} + B_{ij} + \sum_{j=0}^{N-1} A_{ij} = 1$，创作者的约束为 $C_j + E_j = 1$。

B.2 用户间交互概率

对于每个用户 j，我们假设其与任意其他用户建立连接的概率如下：

$$\text{Prob(user } j \text{ influences user } i) = \exp(-\delta||u_i^0 - u_j^0||_2^2)$$

其中，u_i^0，$u_j^0 \in [-1,1]^n$ 是用户 i 和 j 在时间 0 的意见向量，$\delta > 0$ 是控制网络连通性的参数。δ 的不同参数会导致不同的连接数量。参数 δ 的不同取值及其产生的平均节点度显示在表 2 中。我们选择 $\delta = 9$，以恢复 11 个邻居。

Tab表 2：不同参数下的网络连通性 δ，其中 $N = 600$ 个用户为随机初始化

参数 δ	平均连接数
6	21
7	17
8	14
9	11

C 合成数据上变分环境的结果

C.1 改变动力学的模拟参数

我们通过设置 $\delta = 6$ 来增加社交互动次数，使每位用户平均拥有 21 个连接。扩展后的社交网络让用户能够通过同伴互动接触到更广泛的观点。图 5a 和图 5b 分别展示了经过 50 个时间步和 500 个时间步后的全局聚类和满意度指标。结果表明，即使采用贪心推荐系统（$d = 0$），更高的社交连通性也能减轻聚类。

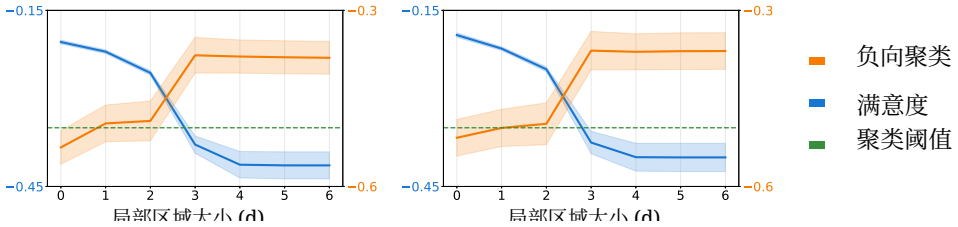

(a) 经过 50 个时间步后　(b) 经过 500 个时间步后

图 5：绘制了 d变化时的全局聚类和全局用户满意度，分别对应 (a) 50 个和 (b) 500 个时间步后的情况；与图 3 相比，社会互动更多。聚类阈值设为 -0.5，此时簇已无法区分。

C.2 改变 Top-k 的 k 值

考察了具备社会意识的推荐系统下，局部化参数为 $d \in \{0,3\}$、推荐集大小为 $k \in \{1,2,3,4\}$ 时的意见动力学。图 6–9 展示了相应的观点分布图。对于 $k = 1$，动力学在 $t = 20$ 后进入稳态（图 6）。由于全局聚类得分较低，省略聚类可视化。随着 k 减小，簇的数量增加，这反映了创作者与用户的互动多样性降低。在所有 k取值下，使用 $d = 3$的推荐系统产生的簇均少于使用 $d = 0$ 的推荐系统。

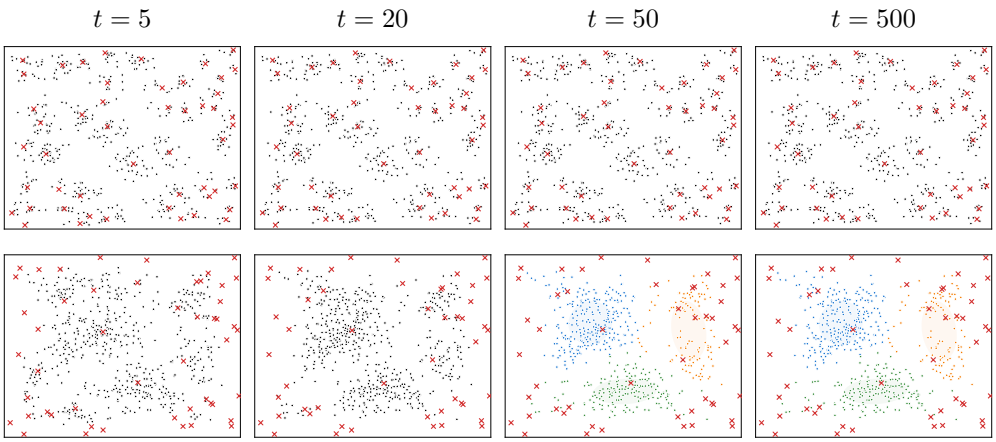

图6：意见环境的快照，其中 $k = 1$ 使用局部区域进行模拟 $d = 0$，第一行， $d = 3$，第二行。 $\times$ 表示创作者， $\bullet$ 分别表示用户。

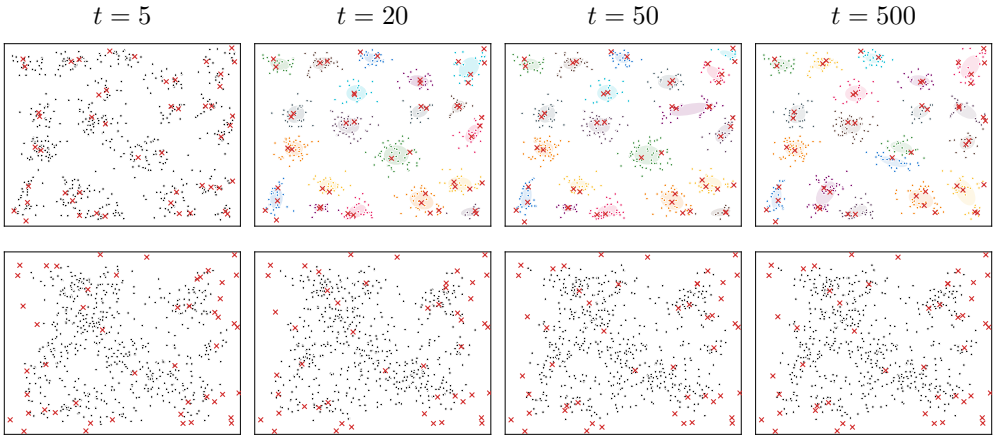

Fig图7：意见环境的快照，其中 $k = 2$ 使用局部区域进行模拟 $d = 0$ ，第一行， $d = 3$，第二行。 $\times$ 表示创作者， $\bullet$ 分别表示用户。

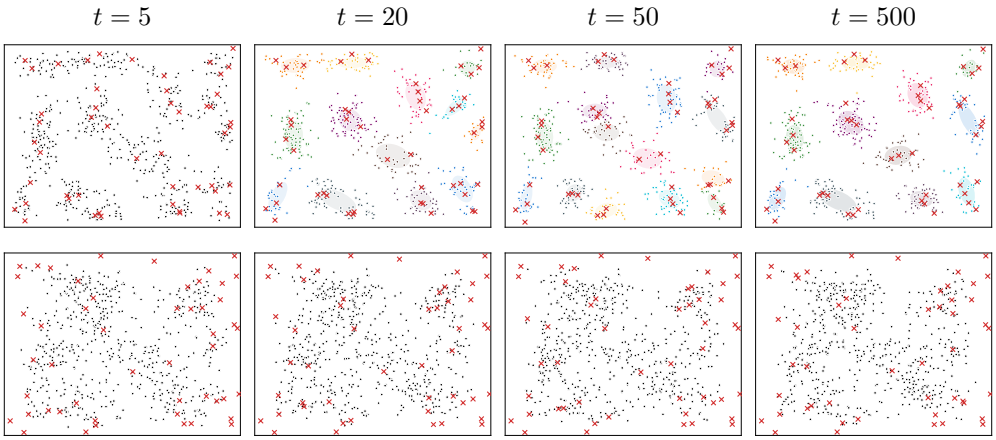

图8：意见环境的快照，其中 $k = 3$ 使用局部区域进行模拟 $d = 0$，第一行， $d = 3$，第二行。 $\times$ 表示创作者， $\bullet$ 分别表示用户。

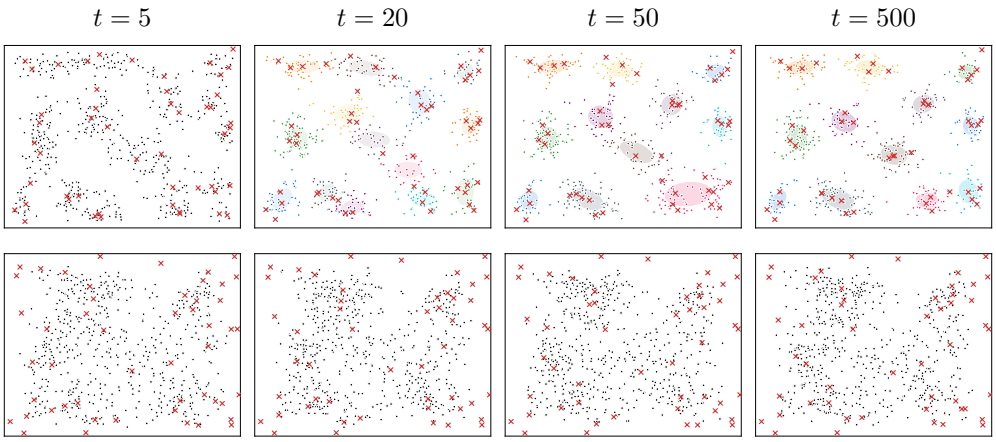

图9：意见环境的快照，其中 $k = 4$ 模拟中包含一个局部区域 $d = 0$，第一行； $d = 3$，第二行。 $\times$ 表示创作者， $\bullet$ 表示用户。

D 真实数据集的环境变量

D.1 用户-创作者动态的参数

方程1中的动力学参数从均匀分布中独立抽取，其取值范围见表3。

表3：均匀分布抽样的模拟参数

参数	**下界**	**上界**
用户参数		
用户固执性 Λ_i	0.0	0.5
用户自我影响 A_{ii}	0.5	0.8
推荐者影响 B_{ij}	0.2	0.8
邻居影响 $\sum_{j=0}^{N-1} A_{ij}$	0.25	0.5
创作者参数		
创作者固执性 Γ_j	0.0	0.5
创作者自我影响 E_j	0.5	0.8
用户-创作者影响力 C_j	0.2	0.8

用户-创作者影响力在创作者 j 的受众集合中平均分配；具体而言，对于拥有受众集合 $\mathcal{F}_j$ 的创作者 j，每位用户 $i \in \mathcal{F}_j$ 施加的影响力为 $C_{ji} = C_j/|\mathcal{F}_j|$。用户 i 受到的整体社会影响由所有邻居施加的影响力之和决定。每位用户恰好受到一位创作者的影响。因此，参照 A 节中的 FJ模型，我们得到以下随机约束： $A_{ii} + B_{ij} + \sum_{j=0}^{N-1} A_{ij} = 1$ 适用于用户， $C_j + E_j = 1$ 适用于创作者。

D.2 EGO-FACEBOOK数据集

该网络由 4039 名匿名用户及其社交连接构成。由此得到的图的平均度为 45，邻居数量为 2 至 1046 不等。我们确定了 34 个社区中心 $\{C_1, C_2, ..., C_{34}\}$，它们随机分布在 $[0, 1]^3$ 中，并应用谱聚类将每位用户分配到指定社区之一。分配完成后，任何被分配到社区中心 j的用户 i，其初始值均设为 $u_i^0 = C_j + \epsilon_i$，其中 $\epsilon_i \sim \mathcal{N}$的取值范围为 (0，0.15)。

E 计算资源

所有模拟和实验均在配备 Apple M2 芯片和 8 GB 统一内存、运行 macOS 15.6.1 的 MacBook Air 上完成。

F 定理与引理证明

F.1 定理1的证明

证明。 证明可通过扩展的 Friedkin-Johnsen 动力学得出，其中

$$\begin{bmatrix} u^{t+1} \\ c^{t+1} \end{bmatrix} = \begin{bmatrix} I-\Lambda & 0 \\ 0 & I-\Gamma \end{bmatrix} \underbrace{\begin{bmatrix} A & B \\ C & E \end{bmatrix}}_{\Pi} \begin{bmatrix} u^t \\ c^t \end{bmatrix} + \begin{bmatrix} \Lambda & 0 \\ 0 & \Gamma \end{bmatrix} \begin{bmatrix} u^0 \\ c^0 \end{bmatrix} \tag{16}$$

其中 $\Pi \in \mathbb{R}^{(N+M)\times(N+M)}$ 为行随机矩阵。根据（Proskurnikov & Tempo，2017，定理21），可知当 $t \to \infty$趋于极限时，我们有

$$\begin{bmatrix} u^{\infty} \\ c^{\infty} \end{bmatrix} = \left(\begin{bmatrix} I & 0 \\ 0 & I \end{bmatrix} - \underbrace{\begin{bmatrix} I-\Lambda & 0 \\ 0 & I-\Gamma \end{bmatrix} \begin{bmatrix} A & B \\ C & E \end{bmatrix}}_{J} \right)^{-1} \begin{bmatrix} \Lambda u^0 \\ \Gamma c^0 \end{bmatrix} \tag{17}$$

根据（$I-J$）$^{-1} \approx \sum_{k=0}^{\infty} J^k$的级数展开，可得 $u^* = \Lambda u(0) + (I-\Lambda)(Au(0) + Bc(0)) + ((I-\Lambda)A)^2 u(0) + (I-\Lambda)B(I-\Gamma)Cu(0) + (I-\Lambda)A(I-\Lambda)Bc(0) + (I-\Lambda)B(I-\Gamma)Ec(0) + h.o.t.$。我们着重关注一阶项（$I-\Lambda$）（$Au(0) + Bc(0)$），并注意到 $[A, B]\vec{1}_{N+M} = \vec{1}_N$，这尤其意味着约束等式：$B_i + \sum_j A_i,\ _j = 1$。因此，通过增强社交网络对用户 i的影响（由 $\sum_j A_i,\ _j$表征），推荐内容的影响（由 B_i 表征）需要降低。 □

F.2 引理1的证明

证明。 注意，在贪心推荐系统下，对于每个用户 i，都有 $r(u_i^t) = \min_j(||c_j^t - u_i^t||_2)$，因此 $u_i^t \in \mathcal{F}_j^t$。此外，给定 $\Gamma = I_M$，有 $c_j^0 = c_j^t, \forall t$，我们简写为 c_j。

归纳假设 假设对于任意用户 i，其观点为 u_i^t，并受方程1中的系统动力学支配，有 u_i^t, $u_i^{t-1} \in \mathcal{F}_j^t \times \mathcal{F}_j^{t-1}$，其中 $(u_i^t - c_j) = \alpha^t(u_i^{t-1} - c_j)$，$\alpha^t \in [\eta, 1]$，且$\eta = (1-\Lambda_i)A_{ii} \in [0, 1]$。也就是说，$(u_i^t - c_j)$ 和 $(u_i^{t-1} - c_j)$ 平行、方向相同，并且 $||u_i^t - c_j|| \le ||u_i^{t-1} - c_j||$。

归纳步骤 利用方程1，我们可以写成

$$\begin{aligned} u_i^t &= (1-\Lambda_i)(A_{ii}u_i^{t-1} + B_i c_j) + \Lambda_i u_i^0 \\ u_i^{t+1} &= (1-\Lambda_i)(A_{ii}u_i^t + B_i c_j) + \Lambda_i u_i^0. \end{aligned} \tag{18}$$

这里用到了矩阵 A 是对角矩阵以及 u_i^t，$u_i^{t-1} \in \mathcal{F}_j^t \times \mathcal{F}_j^{t-1}$ 这一事实。为简化记号，我们省略了方程18中的克罗内克积。利用 $\Lambda_i u_i^0 = u_i^t - (1-\Lambda_i)(A_{ii}u_i^{t-1} + B_i c_j)$，可得

$$\begin{aligned} u_i^{t+1} &= -(1-\Lambda_i)A_{ii}(u_i^{t-1} - u_i^t) + u_i^t \Rightarrow \\ (u_i^{t+1} - c_j) &= (u_i^t - c_j) - (1-\Lambda_i)A_{ii}(u_i^{t-1} - u_i^t). \end{aligned}$$

直观而言，这表示用户意见 u_i^{t-}，u_i^t，u_i^{t+} 与创作者意见 c_j 位于同一直线上。现在令 $\eta = (1-\Lambda_i)A_{ii} \in [0, 1]$，我们可以写成

$$\begin{aligned} u_i^{t+1} - c_j &= (u_i^t - c_j) - \eta(u_i^{t-1} - u_i^t) \\ &= (u_i^t - c_j) - \eta((u_i^{t-1} - c_j) - (u_i^t - c_j)) \\ &= (1+\eta)(u_i^t - c_j) - \eta(u_i^{t-1} - c_j) \\ &= (1+\eta)(u_i^t - c_j) - \eta/\alpha^t(u_i^t - c_j) \\ &= (1+\eta-\eta/\alpha^t)(u_i^t - c_j). \end{aligned}$$

第四个等式由归纳假设得出，即：$(u_i^t - c_j) = \alpha^t(u_i^{t-1} - c_j)$。现在我们观察到

$$\alpha^t \in [\eta, 1] \Rightarrow (1 + \eta - \eta/\alpha^t) \in [\eta, 1].$$

现在令 $\alpha^{t+1} = (1 + \eta - \eta/\alpha^t)$，这将导出所需性质： $u_i^{t+1} - c_j = \alpha^{t+1}(u_i^t - c_j)$，其中 $\alpha^{t+1} \in [\eta, 1]$，且 $\eta = (1 - \Lambda_i)A_{ii}$。我们可以利用这一性质进一步推导出$||u_i^{t+1} - c_j||_2 \leq ||u_i^t - c_j||_2$。由于所有其他创作者同样都是固执用户，这直接意味着在贪心推荐系统下： $u_i^{t+1} \in F_j^{t+1}$ 。

基础情况归纳步骤如下：

$$\begin{aligned}
&u_i^0 \in \mathcal{F}_j^0 \Rightarrow \\
&u_i^1 = (1 - \Lambda_i)(A_{ii}u_i^0 + B_i c_j) + \Lambda_i u_i^0 \\
&u_i^1 = (1 - \Lambda_i)(A_{ii}u_i^0 + (1 - A_{ii})c_j) + \Lambda_i u_i^0 \\
&u_i^1 = ((1 - \Lambda_i)A_{ii} + \Lambda_i)u_i^0 + (1 - \Lambda_i)(1 - A_{ii})c_j \Rightarrow \\
&u_i^1 - c_j = ((1 - \Lambda_i)A_{ii} + \Lambda_i)(u_i^0 - c_j).
\end{aligned}$$

现在只需注意到： $\eta = (1-\Lambda_i)A_{ii} \leq ((1-\Lambda_i)A_{ii}+\Lambda_i) = \alpha^1 \leq 1$，即可完成证明。我们得出 $u_i^1 - c_j = \alpha^1(u_i^0 - c_j)$，其中 $\alpha^1 \in [\eta, 1]$；鉴于用户是固执用户，这意味着 u_i^0， $u_i^1 \in \mathcal{F}_j^0 \times \mathcal{F}_j^1$。因此，用户分区 $\mathcal{F}_0, .., \mathcal{F}_M$实际上在贪心推荐系统下是静态的，并且对于任意用户 $i \in \mathcal{F}_j$，其与创作者 $||u_i^t - c_j||_2$之间的距离会随着 α^t单调递减。

□

G 相关工作

为更好地定位本文，下表以示意方式总结了相关工作，将用户和创作者归类为静态（S）或动态（D），并区分其被视为嵌入网络（N）中还是孤立（I）。对于推荐系统，我们区分其是固定（F），即取自现有文献，还是显式设计（ED）。

	用户	**创作者**	**推荐系统**
Us	D,N	D, I	ED
Lin 等人（2024）	D,I	D,I	F
Rossi 等人（2022）	D,I	N/A	ED
Lanzetti 等人（2023）	D,I	N/A	ED
Dean 等人（2024b）	D,I	D,I	ED
Ma 等人（2008）	S,N	N/A	F
Chandrasekaran 等人（2024）	D,N	N/A	ED
Ziegler 等人（2005）	S,I	N/A	ED
Cheng 等人（2017）	S, I	N/A	ED
Zhang 等人（2023）	S,I	N/A	ED
Zhang & Hurley（2008）	S,I	N/A	ED