

カスケードグラフ学習による偽・誤情報の早期検出

代表研究者

津川 翔

筑波大学 システム情報系 准教授

1 はじめに

ソーシャルメディアは、災害、感染症、選挙、社会運動などに関する情報が短時間で広く共有される重要な情報基盤となっている。一方で、偽情報、誤情報、噂、組織的な世論操作キャンペーンなども同じ仕組みを通じて急速に拡散する。こうした有害な情報拡散は、社会不安、誤った意思決定、公共的議論への影響を引き起こす可能性があるため、拡散が大規模化する前に早期に検出する技術が求められている [1, 2]。

偽・誤情報の検出には、投稿本文の内容を分析する方法、発信者の属性や過去の行動を用いる方法、拡散に関与したユーザー間の関係を用いる方法などがある。本研究では、このうち情報が「どのように広がったか」という拡散構造に着目する。ある投稿や記事が、誰から誰へ、どの順序で、どの程度広がったかを表す拡散履歴は情報カスケードと呼ばれる。これを、ユーザーをノード、情報の伝播関係をリンクとするグラフとして表現したものがカスケードグラフである。

投稿本文に基づく検出は、言語、話題、表現の変化に強く依存し、悪意ある発信者によって意図的に改変される可能性もある。これに対して、カスケードグラフに基づく方法は、情報の内容そのものではなく、広がり方に表れる特徴を利用する [3, 6]。自然発生的な話題の拡散、偽・誤情報の拡散、組織的キャンペーンによる拡散では、拡散の速さ、枝分かれの仕方、中心的なユーザーの関与、局所的な密集構造などに違いが表れる可能性がある。そのため、カスケードグラフの構造的・時間的特徴を学習することは、本文分析を補完する有効な手がかりとなる。

しかし、カスケードグラフに基づく偽・誤情報検出には二つの大きな課題がある。第一に、高品質なラベル付きデータを大量に集めることが難しい。新しい偽・誤情報や組織的キャンペーンが発生した直後には、それが問題のある拡散であるかを判定するための教師データは限られている。第二に、早期検出では、拡散が完了した後のカスケード全体を利用できない。実用上重要なのは、拡散開始後の短い時間に観測された部分的なカスケードから、危険な拡散の兆候を見つけることである。

本研究では、これらの課題に対して、カスケードグラフ学習に基づく偽・誤情報の早期検出手法を検討した。特に、Contrastive Cascade Graph Learning (CCGL) と呼ばれる対照学習型のカスケード表現学習に着目した [4]。CCGL は、ラベルのない多数のカスケードから拡散構造の特徴を事前に学習し、その後、少量のラベル付きデータを用いて目的の分類タスクに適応させる手法である。この枠組みにより、ラベル付きデータが限られる状況でも、カスケードの構造的特徴に基づく分類が可能になると期待される。図 1 に本研究の全体像を示す。

本研究では、主に以下の三点に取り組んだ。第一に、CCGL がカスケードグラフの構造的特徴をどの程度捉えられるかを、合成データおよび実世界データを用いて評価した。第二に、CCGL の性能を、特徴量ベースの機械学習手法、グラフニューラルネットワーク、時系列型のカスケードモデルなどと比較し、どのような条件下で有効であるかを検証した。第三に、少量のラベル付きデータしか利用できない場合や、拡散開始後の短い観測期間しか利用できない場合にも、カスケードグラフに基づく検出が




図 1：本研究の全体像

有効に機能するかを調べた。なお、本研究の中心的な評価では、偽・誤情報そのものを直接分類するのではなく、偽・誤情報検出に必要となる拡散構造の表現能力を検証するため、カスケードの由来や拡散メカニズムを識別する分類タスクを用いた。

本報告書では、2章でカスケードグラフ学習と CCGL の基本的な考え方を説明する。3章では、合成データおよび実世界データを用いたカスケード分類実験について述べる。4章では、少量ラベル条件および事前学習データの選択が分類性能に与える影響を分析する。5章では、組織的キャンペーン検出における観測期間の影響を検討する。最後に6章で、本研究の成果、限界、今後の展望について述べる。

2 カスケードグラフ学習と CCGL

本章では、本研究で用いたカスケードグラフ学習と Contrastive Cascade Graph Learning (CCGL) [4] の基本的な考え方を説明する。ここでは数式による厳密な定義ではなく、偽・誤情報の早期検出において、なぜ情報拡散の「形」を学習することが有効なのかを中心に述べる。

2-1 情報拡散をカスケードグラフとして捉える

ソーシャルメディアでは、ある投稿を見たユーザーがリツイート、返信、引用、共有などの行動を行い、それを見た別のユーザーがさらに反応することで、情報が連鎖的に広がっていく。このような拡散の履歴を「情報カスケード」と呼ぶ。情報カスケードを、ユーザーを点、情報が伝わった関係を線として表したものが「カスケードグラフ」である。

カスケードグラフには、単に何人に広がったかだけでなく、どのような経路で広がったか、どの程度枝分かれしたか、中心的なユーザーを介して広がったか、短時間で急激に広がったか、といった情報が含まれる。たとえば、自然発生的な話題の拡散と、人為的に増幅された組織的キャンペーンでは、同じ程度の規模に見えても、拡散の形や時間的な広がり方が異なる可能性がある。図2にカスケードグラフの例を示す。

偽・誤情報検出においてカスケードグラフを用いる利点は、投稿本文だけに依存しない点にある。本文に基づく検出では、言語、話題、表現の違いによって性能が左右される。また、悪意ある発信者が表現を変えることで検出を回避する可能性もある。これに対して、カスケードグラフに基づく方法では、情報の「内容」ではなく「広がり方」に着目する。そのため、本文分析を補完する手がかりとして、拡散構造の分析は重要である。

2-2 少量ラベル条件に向けた CCGL の考え方

カスケードグラフを分類するには、グラフの特徴を機械学習モデルに学習させる必要がある。従来は、カスケードサイズ、拡散の深さ、リンク密度、平均次数などの特徴量を人手で設計し、それを分類器に入力する方法が用いられてきた。しかし、どの特徴が有効かはデータやタスクによって異なるため、汎用的な特徴設計は容易ではない。また、グラフニューラルネットワークなどの深層学習手法を用いる場合にも、十分なラベル付きデータが必要になる。

この課題に対して、本研究では CCGL に着目した。CCGL は、ラベルのない多数のカスケードから、拡散構造を表す特徴を事前に学習する手法である。基本的な考え方は、同じカスケードから作られた少し異なる二つのグラフは似たものと




図 2：情報カスケードとカスケードグラフの例

して扱い、別のカスケードから作られたグラフとは区別できるようにモデルを学習させる、というものである。このような学習方法を対照学習と呼ぶ。

CCGL の処理は、大きく三つの段階に分けられる。第一に、元のカスケードグラフから、拡散過程として不自然にならない範囲で少し異なるグラフを作る。第二に、同じカスケードから作られたグラフ同士が近く、異なるカスケードから作られたグラフ同士が離れるように、カスケードの表現を事前学習する。第三に、得られた表現を用いて、少量のラベル付きデータで目的の分類タスクに適応させる。

この枠組みは、偽・誤情報検出と相性がよい。偽・誤情報や組織的キャンペーンのラベルを大量に集めることは難しい一方で、ラベルのない拡散データは比較的多く存在する。CCGL を用いれば、まずラベルなしデータから一般的な拡散パターンを学習し、その後、限られたラベル付きデータで偽・誤情報検出やキャンペーン検出に適応できる可能性がある。

2-3 早期検出との関係

偽・誤情報対策では、拡散が十分に進んだ後に分類できるだけでは不十分である。社会的な影響を抑えるためには、拡散の初期段階で危険な情報拡散の兆候を見つける必要がある。そのため、カスケード全体ではなく、拡散開始後の短い時間に観測された部分的なグラフから分類できることが重要となる。

拡散初期のカスケードは、ノード数やリンク数が少なく、利用できる情報が限られている。しかし、短時間に多数のユーザーが反応する、特定のユーザー群の内部で集中的に広がる、中心的なアカウントを介して急速に拡散する、といった特徴は、初期段階にも現れる可能性がある。カスケードグラフ学習は、このような早期の構造的手がかりを抽出するための方法として有望である。

本研究では、CCGL によってカスケード構造の特徴を学習し、それを少量ラベル条件および短い観測期間での分類に応用することを目指した。次章では、合成データおよび実世界データを用いて、CCGL がどの程度カスケードの構造的特徴を捉えられるかを評価する。

3 カスケード分類実験による CCGL の評価

本章では、CCGL が情報拡散カスケードの構造的特徴をどの程度捉えられるかを評価するために行ったカスケード分類実験について述べる。本研究の目的は、特定のデータセットに対して高い精度を得ることだけでなく、CCGL が情報拡散の「形」の違いを学習できるかを明らかにすることである。そのため、拡散過程を人工的に生成した合成データと、実際のソーシャルメディア等から得られた実世界データの両方を用いて評価を行った。

3-1 評価に用いたデータと比較手法

合成データでは、ネットワーク構造と情報拡散モデルを組み合わせるカスケードを生成した。ネットワーク構造としては、ハブを持つネットワーク、小さな世界性を持つネットワーク、コミュニティ構造を持つネットワークなど、性質の異なるモデルを用いた。また、情報拡散モデルとしては、隣接ノードに確率的に情報が伝わるモデル、しきい値を超えると情報を採用するモデル、ユーザーの属性や関心を反映したモデルを用いた。これにより、拡散の仕組みや基盤となるネットワークの違いが、カスケードグラフの形にどのように表れるかを制御した条件で評価できる。

実世界データでは、Twitter、Weibo、Douban、Stack Exchange、学術引用データなど、複数のプラットフォームに由来するカスケードを用いた。これらのデータは、投稿の再共有、レビュー、コメント、論文引用など、拡散の仕組みが互いに異なる。また、カスケードの平均的な大きさにも違いがあるため、平均カスケードサイズに基づいて、Small、Medium、Large の三つのグループに分けて評価した。

比較対象としては、人手で設計した特徴量を用いる Random Forest および LightGBM、グラフニューラルネットワークである GCN、時系列的な拡散過程を扱う DeepHawkes、カスケード表現学習モデルである CasFlow を用いた。これらと CCGL を比較することで、CCGL がどのような条件で有効であるかを検証した。評価指標には、各クラスの分類性能をバランスよく評価できる F1 値を用いた。

3-2 合成データによる評価

まず、合成データを用いて、CCGL が拡散モデルやネットワーク構造の違いを識別できるかを評価した。図 3 に、合成データにおける分類結果の概要を示す。




図 3：合成データにおける分類精度 [5]

拡散モデルを分類するタスクでは、CCGL はすべてのネットワーク条件で高い性能を示した。具体的には、いずれのネットワーク構造においても F1 値は 0.96 以上であり、情報がどのような仕組みで広がったかを、カスケードグラフの構造から安定して識別できることが分かった。DeepHawkes も一部の条件では非常に高い性能を示したが、ネットワーク構造が変わると性能が低下する場合があった。これに対して、CCGL は条件の違いに対して比較的安定しており、観測されたカスケード構造に表れる拡散過程の違いを捉える能力が高いことが示唆された。

一方、ネットワークモデルを分類するタスクでは、DeepHawkes が最も高い性能を示す場合が多かった。このタスクでは、同じ拡散モデルのもとで、基盤となるネットワーク構造が異なるカスケードを識別する必要がある。拡散後に観測されるカスケードは、元のネットワーク全体の一部でしかないため、基盤ネットワークの構造を復元することは難しい。したがって、この結果は、CCGL が常にすべての分類タスクで最良となるわけではないことを示している。ただし、CCGL も多くの条件で比較的高い性能を示しており、拡散構造に含まれる情報を一定程度捉えられていることが確認された。

これらの結果から、CCGL は、特に「情報がどのような拡散メカニズムに従って広がったか」を識別するタスクに強いことが分かった。この性質は、偽・誤情報や組織的キャンペーンの検出において重要である。なぜなら、それらの検出では、個々のユーザー間の潜在的なネットワーク構造そのものよりも、実際に観測された拡散過程の違いを捉えることが重要だからである。

3-3 実世界データによる評価

次に、実世界データを用いて、CCGL が実際の情報拡散カスケードを分類できるかを評価した。図 4 に、Small、Medium、Large の各グループにおける分類性能を示す。

実世界データでは、CCGL は Medium グループおよび Large グループで最も高い性能を示した。Medium グループでは、CCGL の F1 値は 0.65 であり、他の主要なベースラインを上回った。Large グループでは、CCGL の F1 値は 0.84 に達し、Random Forest、LightGBM、GCN、DeepHawkes、CasFlow のいずれよりも高い性能を示した。特に、カスケードサイズが比較的大きく、構造的な違いが十分に含まれるデータでは、CCGL が有効であることが確認された。




図 4：実世界データにおける分類精度 [5]

一方、Small グループでは、CCGL は最良ではなく、DeepHawkes が最も高い性能を示した。Small グループは主に学術引用データから構成されており、平均カスケードサイズが小さい。カスケードが小さい場合、グラフ構造から得られる情報は限られる。そのため、構造表現を重視する CCGL よりも、時系列的な拡散過程を扱う手法が有利になったと考えられる。この結果は、CCGL の適用には、ある程度の構造的情報を含むカスケードが必要であることを示している。

分類誤りの傾向を詳細に分析すると、CCGL はプラットフォームの違いを比較的良好に捉えていることが分かった。たとえば、Twitter 由来のカスケードと Douban 由来のカスケードは、全体として区別されやすい。一方で、同じプラットフォームに由来するデータセット同士では混同が見られた。これは、CCGL がプラットフォームごとの拡散構造の特徴を強く捉えていることを示している。同時に、同じプラットフォーム内のより細かな違いを識別するには、追加の情報やモデルの改良が必要であることも示唆している。

3-4 得られた知見

本章の実験から、CCGL はカスケードグラフの構造的特徴を有効に学習できることが確認された。特に、拡散メカニズムの違いや、構造的に豊かな実世界カスケードの分類において高い性能を示した。この結果は、CCGL が単にカスケードの規模を見るだけではなく、拡散の枝分かれ、深さ、局所的な構造、プラットフォームごとの拡散様式などを反映した表現を学習している可能性を示すものである。

一方で、CCGL が常に最良の手法であるわけではないことも明らかになった。小規模なカスケードや、基盤ネットワーク構造の推定が重要なタスクでは、時系列モデルなどの別の手法が有利になる場合があった。したがって、CCGL は万能な分類器ではなく、カスケードに十分な構造的情報が含まれる場合に特に有効な手法であると位置づけられる。


以上の結果は、偽・誤情報や組織的キャンペーンの検出に向けて重要な示唆である。偽・誤情報の拡散では、投稿内容だけでなく、拡散の仕方そのものに特徴が表れる可能性がある。CCGL は、そのような拡散構造をラベルなしデータから事前に学習し、分類タスクに活用できる。次章では、この性質が、ラベル付きデータが少ない状況でどの程度有効に働くかを検証する。

4 少量ラベル条件と事前学習データの影響


偽・誤情報や組織的キャンペーンの検出では、十分な量のラベル付きデータを利用できるとは限らない。新しい社会的イベントや選挙、災害、感染症などに関する情報拡散では、問題のある投稿やキャンペーンが発生してから、それを人手で確認し、正解ラベルを付けるまでに時間がかかる。そのため、実用的な早期検出システムには、少量のラベル付きデータでも高い性能を維持できることが求められる。本章では、ラベル付きデータの量と、事前学習に用いるデータの種類の、CCGL の分類性能に与える影響を検討する。

4-1 ラベル付きデータ量を減らした場合の性能


まず、訓練に用いるラベル付きデータの割合を段階的に減らし、各手法の分類性能の変化を調べた。ここでは、3章で用いた実世界カスケードデータを対象に、Small、Medium、Large の各グループで実験を行った。図 5 に、ラベル付きデータの割合を変化させた場合の F1 値を示す。



(a) Small Group



(b) Medium Group



(c) Large Group

図 5：ラベル付きデータ量と分類精度の関係 [5]

図 5 より、CCGL は、特に Medium グループおよび Large グループにおいて、ラベル付きデータを減らして

も比較的安定した性能を示した。ラベル付きデータをすべて用いた場合だけでなく、20%程度まで減らした場合でも、性能の低下は限定的であった。これは、CCGL が事前学習の段階で、ラベルに依存しないカスケード構造の特徴を学習しており、その表現が少量ラベル条件でも有効に働いていることを示している。


一方で、ラベル付きデータを極端に少なくした場合には、CCGL を含む多くの手法で性能が低下した。これは、事前学習によって一般的な拡散構造を学習できたとしても、最終的にどの構造がどのクラスに対応するかを学ぶためには、一定量のラベル付きデータが必要であることを意味する。したがって、CCGL はラベル不足の影響を軽減できるが、完全にラベルを不要にするものではない。

この結果は、偽・誤情報の早期検出にとって重要である。現実の応用では、大量の教師データを準備できない状況が多い。CCGL のような事前学習型の手法を用いることで、少量の確認済み事例をもとに分類モデルを構築できる可能性がある。一方で、極端にラベルが少ない段階では、モデルの出力をそのまま自動判定に用いるのではなく、人手確認や追加データ収集と組み合わせて利用する必要がある。


4-2 事前学習データの種類と量の影響

次に、事前学習に用いるデータの種類と量が分類性能に与える影響を調べた。CCGL では、ラベルのないカスケードデータを用いて拡散構造の表現を事前学習する。そのため、どのようなデータを事前学習に用いるかが、下流の分類性能に影響する可能性がある。


本研究では、通常の CCGL に加えて、二つの拡張条件を比較した。一つは、利用可能な実世界カスケードをより多く事前学習に用いる条件である。もう一つは、人工的に生成した大規模な合成カスケードを事前学習に用いる条件である。合成カスケードは、ネットワークモデルと拡散モデルを組み合わせで生成したものであり、多様な拡散構造を制御された条件で作出できるという利点がある。図 6 に、事前学習データの種類を変えた場合の分類性能を示す。



(a) Small Group



(b) Medium Group



(c) Large Group

図 6：事前学習データの違いによる分類精度の比較[5]

Small グループおよび Large グループでは、事前学習データを増やすことで性能が改善した。特に、ラベル付きデータが少ない条件では、より多くのラベルなしデータを用いた事前学習が有効であった。また、合成カスケードを用いた事前学習でも、実世界データを多く用いた場合と同程度の性能が得られる場合があった。この結果は、実世界のラベルなしカスケードを十分に集めることが難しい場合でも、合成データが事前学習の補助的資源として利用できる可能性を示している。

ただし、この効果はすべての条件で一貫して見られたわけではない。Medium グループでは、事前学習データを増やした場合や合成データを用いた場合に、必ずしも性能が向上しなかった。これは、事前学習データの分布と、分類したい対象データの分布が十分に合っていない場合、事前学習がかえって分類に不利に働く可能性を示している。このような現象は、一般に負の転移と呼ばれる。すなわち、多くのデータを使えば必ず性能が上がるわけではなく、分類タスクに関係する構造的特徴を含むデータを選ぶことが重要である。

4-3 偽・誤情報検出への示唆

本章の結果から、CCGL の有効性は、少量ラベル条件と事前学習データの設計に強く関係することが分かった。まず、CCGL は、ある程度のラベル付きデータがあれば、ラベル量を大きく減らしても性能を維持できる場合がある。これは、偽・誤情報や組織的キャンペーンのように、ラベル付き事例の収集が難しい対象に対して有用である。

一方で、事前学習に用いるデータの選択は慎重に行う必要がある。対象タスクに近い拡散構造を含むデータを用いる場合には、事前学習によって性能が向上する可能性がある。しかし、事前学習データと対象データの性質が大きく異なる場合には、負の転移により性能が低下する可能性もある。したがって、実用上は、事前学習データの量だけでなく、プラットフォーム、拡散メカニズム、カスケードサイズ、時間的特徴などの近さを考慮することが重要である。

5 観測期間が早期検出性能に与える影響

偽・誤情報や組織的キャンペーンの検出では、最終的に大きく拡散した後のカスケードを分類できるだけでは不十分である。実際の対策では、拡散が社会的影響を及ぼす前に、できるだけ早い段階で問題のある拡散を検出する必要がある。そのためには、カスケード全体ではなく、拡散開始後の短い時間に観測された部分的なカスケードからでも、有用な構造的特徴を得られるかを確認する必要がある。

本章では、カスケードグラフの観測期間が検出精度に与える影響を調べた実験について述べる。ここでの目的は、CCGL の性能を直接評価することではなく、カスケードグラフに基づく検出手法一般において、どの程度の観測期間があれば分類に必要な情報が得られるかを検討することである。これは、CCGL を偽・誤情報の早期検出へ応用する際にも重要な基礎的知見となる。

5-1 実験の概要

対象としたのは、ソーシャルメディア上の組織的キャンペーン検出である。組織的キャンペーンとは、人為的な介入によって特定のトピックを意図的に拡散させたり、トレンド化させたりする活動である。このような活動は、一見すると通常的话题拡散と似ている場合があるが、関与するユーザーのつながり方や、短時間での反応の集中などに特徴が表れる可能性がある。

実験では、既存手法である DECODE [6] を用いた。DECODE は、カスケードグラフ上の構造的特徴をもとに、対象のカスケードが「組織的キャンペーン」か「自然発生的なトレンド」かを識別する手法である。評価データには、2023 年トルコ選挙に関連するカスケードデータを用いた。このデータには、組織的キャンペーンに対応するグラフと、非キャンペーンに対応するグラフが含まれる。

観測期間の影響を調べるため、各カスケードについて、最初のエンゲージメントが発生した時刻を起点とし、その後 τ 分以内に生成されたノードとリンクだけを抽出した。つまり、 τ が短い場合には拡散初期の小さな部分グラフだけを使い、 τ が長い場合にはより完成に近いカスケードを使うことになる。このように観測期間 τ を段階的に変化させ、それぞれの条件で分類性能を評価した。

5-2 観測期間と分類性能

図 7 に、観測期間 τ を変化させたときの分類性能を示す。横軸は観測期間、縦軸は F1 値であり、各点は複数回試行の平均値、エラーバーはばらつきを表している。




図 7: 観測期間と組織的キャンペーン検出精度の関係 [7]

結果として、観測期間が 1 時間の場合には検出性能が低くなる一方、2 時間から 24 時間の範囲では、分類性能に大きな差は見られなかった。これは、組織的キャンペーンの検出に必要な構造的特徴の多くが、拡散開始後の比較的早い段階で現れている可能性を示している。すなわち、長期間の拡散を待たなくても、およそ 2 時間程度の観測があれば、分類に有用なカスケード構造を一定程度取得できることが示唆される。

この結果は、早期検出の観点から重要である。偽・誤情報や組織的キャンペーンは、時間が経つほど拡散範囲が広がり、訂正や抑制が難しくなる。そのため、24 時間後に高精度で検出できることよりも、数時間以内に一定の精度で検出できることの方が実用上重要な場合が多い。本実験は、カスケードグラフに基づく検出が、このような早期検出の要件を満たし得ることを示す結果である。

5-3 考察

本章の結果から、カスケードグラフを用いた組織的キャンペーン検出では、必ずしもカスケード全体を長期間観測する必要はないことが分かった。特に、拡散開始後 2 時間程度の観測でも、検出に必要な構造的特徴が得られる可能性が示された。この知見は、偽・誤情報検出への応用においても有用である。偽・誤情報が大規模化する前に検出するためには、短時間で得られる部分的なカスケードから、危険な拡散の兆候を捉える必要があるためである。

一方で、本実験には限界もある。第一に、対象としたデータは 2023 年トルコ選挙に関する組織的キャンペーンデータであり、他の国、言語、プラットフォーム、トピックでも同じ結果が得られるとは限らない。第二に、本実験で用いた手法は DECODE であり、CCGL を用いた場合の観測期間依存性については、今後さらに検証する必要がある。第三に、2 時間程度の観測が有効であるという結果は、対象データにおける平均的な傾向であり、個別のカスケードによっては、より長い観測期間が必要となる可能性もある。

以上より、カスケードグラフに基づく検出では、短い観測期間でも有用な構造的情報を取得できる可能性があることが示された。今後は、CCGL のような事前学習型のカスケード表現学習と、短時間観測に基づく早期分類を組み合わせることで、少量ラベルかつ短時間観測という実用上厳しい条件に対応できる偽・誤情報検出手法の構築を進めることが重要である。

6 おわりに

本研究では、ソーシャルメディア上で拡散する偽・誤情報や組織的キャンペーンを早期に検出するための基盤技術として、カスケードグラフ学習に基づく手法を検討した。特に、情報拡散の履歴をカスケードグラフとして表現し、その構造的・時間的特徴を機械学習モデルに学習させることで、投稿本文の内容だけに依存しない検出が可能となるかを評価した。中心的な手法として、ラベルのないカスケードデータから拡散構造の特徴を事前学習できる Contrastive Cascade Graph Learning (CCGL) に着目し、合成データ、実世界データ、少量ラベル条件、事前学習データの違い、観測期間の短さといった観点から、その有効性と限界を検証した。

本研究で得られた成果は、大きく三点に整理できる。第一に、CCGL がカスケードグラフの構造的特徴を有効に学習できることを示した。合成データを用いた実験では、CCGL は特に拡散モデルの違いを高い精度で識

別できた。これは、CCGL が観測されたカスケードの形から、情報がどのような仕組みで広がったかを捉えられることを示している。また、実世界データを用いた実験では、カスケードサイズが中程度または大きく、構造的な情報を十分に含むデータにおいて、CCGL が主要な比較手法を上回る性能を示した。この結果は、偽・誤情報や組織的キャンペーンの検出において、拡散構造の学習が有効な手がかりになり得ることを示すものである。

第二に、CCGL が少量ラベル条件において有効である可能性を確認した。偽・誤情報検出では、信頼できるラベル付きデータを大量に収集することが難しい。特に、新しいトピックや新しいキャンペーンが発生した直後には、十分な教師データが存在しないことが多い。本研究では、ラベル付きデータ量を段階的に減らした場合の分類性能を評価し、一定程度までラベルを減らしても CCGL が比較的安定した性能を維持することを確認した。これは、ラベルなしデータを用いた事前学習によって、カスケード構造の一般的な特徴があらかじめ学習されているためだと考えられる。一方で、ラベル付きデータを極端に少なくした場合には性能が低下したため、完全にラベルを不要にするものではなく、少量の信頼できる教師データと組み合わせる利用することが重要である。

第三に、早期検出において重要となる観測期間の影響を検討した。組織的キャンペーン検出を対象とした実験では、カスケード開始後の限られた時間に観測された部分グラフを用いて分類性能を評価した。その結果、観測期間が 1 時間の場合には精度が低い一方、2 時間以降では 24 時間まで観測した場合と比べて大きな性能差が見られなかった。このことは、カスケードグラフに基づく検出では、拡散の初期段階にも分類に有用な構造的特徴が現れる可能性を示している。偽・誤情報対策では、拡散が社会的影響を及ぼす前に検出することが重要であり、この結果は早期検出システムの実現に向けた重要な知見である。

一方で、本研究にはいくつかの課題も残されている。第一に、CCGL の有効性はデータの性質に依存する。小規模なカスケードや、構造的な違いが十分に表れないデータでは、時系列モデルなど他の手法が有利となる場合があった。したがって、CCGL は万能な手法ではなく、カスケードに十分な構造的情報が含まれる場合に特に有効な手法として位置づける必要がある。第二に、事前学習データの選択が分類性能に大きく影響する。事前学習データと対象データの性質が近い場合には性能向上が期待できるが、分布が大きく異なる場合には負の転移が生じる可能性がある。そのため、今後は、どのようなカスケードデータが事前学習に適しているかを体系的に整理する必要がある。第三に、観測期間に関する実験は特定の組織的キャンペーンデータを対象としたものであり、他の国、言語、プラットフォーム、トピックでも同様の結果が得られるかは今後の検証課題である。

今後の展望としては、まず、CCGL を実際の偽・誤情報検出データにより直接的に適用し、本文情報やユーザー属性情報と組み合わせた総合的な検出モデルへ発展させることが考えられる。本研究では拡散構造に焦点を当てたが、実用的な検出システムでは、内容、発信者、拡散構造の情報を相補的に利用することが望ましい。次に、短時間観測に対応した CCGL の拡張が重要である。拡散初期の部分グラフは情報量が限られるため、部分的なカスケードからでも安定した表現を得るための学習方法や、時間の経過に応じて判定を更新する逐次的な分類手法が必要となる。さらに、合成カスケードを用いた事前学習についても、より現実的な拡散過程を再現する生成モデルを導入することで、実世界データが少ない状況でも高性能なモデルを構築できる可能性がある。

【参考文献】

- [1] Mian, A., Khan, S.: Coronavirus: The spread of misinformation. BMC Medicine 18(1), 89 (2020).
- [2] Tasnim, S., Hossain, M.M., Mazumder, H.: Impact of rumors and misinformation on COVID-19 in social media. Journal of Preventive Medicine and Public Health 53(3), 171–174 (2020).
- [3] Xu, H., Gao, C., Li, X., Wang, Z.: D2: Customizing two-stage graph neural networks for early rumor detection through cascade diffusion prediction. In: Proceedings of the Eighteenth ACM International Conference on Web Search and Data Mining (WSDM 2025), pp. 568–576 (2025).
- [4] Xu, X., Zhou, F., Zhang, K., Liu, S.: CCGL: Contrastive cascade graph learning. IEEE Transactions on Knowledge and Data Engineering 35(5), 4539–4554 (2023).
- [5] Shibao, N., Tsugawa, S.: Evaluating contrastive cascade graph learning for diffusion pattern classification. Social Network Analysis and Mining (to appear, 2026).

- [6] Gopalakrishnan, A.A., et al.: Density-aware walks for coordinated campaign detection. In: Proceedings of the European Conference on Machine Learning and Principles and Practice of Knowledge Discovery in Databases (ECML PKDD 2025) (2025).
- [7] 服部暉大, 津川翔: カスケードグラフの観測期間がソーシャルメディア上での組織的キャンペーン検出の精度に与える影響に関する一考察。電子情報通信学会総合大会講演論文集, B-11-16, 2026 年 3 月。

〈発 表 資 料〉

題 名	掲載誌・学会名等	発表年月
Evaluating contrastive cascade graph learning for diffusion pattern classification	Social Network Analysis and Mining	2026 年 6 月 (採択決定)
Contrastive cascade graph learning for classifying real and synthetic information diffusion patterns	Proceedings of the 2025 International Conference on Advances in Social Networks Analysis and Mining (ASONAM 2025)	2025 年 8 月
カスケードグラフの観測期間がソーシャルメディア上での組織的キャンペーン検出の精度に与える影響に関する一考察	電子情報通信学会総合大会講演論文集	2026 年 3 月
カスケードグラフ学習フレームワーク CGL による実データ・合成データのカスケード分類精度に関する検討	電子情報通信学会コミュニケーションクオリティ学生ワークショップ	2025 年 8 月
カスケードグラフの構築方法がソーシャルメディア上の偽・誤情報検出精度に与える影響に関する一考察	電子情報通信学会コミュニケーションクオリティ学生ワークショップ	2025 年 8 月