

# 動的なソーシャルネットワークにおける 興味関心の伝搬を考慮した将来予測モデル

伊藤 寛祥<sup>†</sup> Christos Faloutsos<sup>††</sup>

<sup>†</sup> 筑波大学

<sup>††</sup> Carnegie Mellon University

E-mail: [fito@slis.tsukuba.ac.jp](mailto:fito@slis.tsukuba.ac.jp), [christos@cs.cmu.edu](mailto:christos@cs.cmu.edu)

**あらまし** 本研究では時間の経過とともに変化するソーシャルネットワークを対象に、未観測の時刻におけるエッジと、ノードの属性値の双方を予測する手法を提案する。本手法では、ノードと属性値の潜在ベクトルの相関に基づく生成モデルを構成し、未観測の時刻における潜在ベクトルを予測することで、未来のソーシャルネットワークの状態を予測する。本研究では特に（１）ネットワーク構造の変化と興味関心の変化の相互作用、および（２）ネットワークを媒介した潜在的な特徴の伝搬に着目したモデル化を行う。ノードと属性値の潜在的な特徴はネットワークを通じて隣接するノードと属性値に伝搬すると仮定し、その過程を取り入れた潜在ベクトルの予測モデルを構成する。ここで、各ノードと属性値はネットワークにおける影響力と受容性のパラメータをもつと仮定し、これらに基づいて時間経過後の潜在ベクトルが予測される。実世界のソーシャルネットワークを用いた実験により、提案手法は既存の手法と比較して、より高精度に未観測の時刻におけるエッジおよびノードの属性値を予測できることを示した。

**キーワード** ソーシャルネットワーク予測

## 1 はじめに

ソーシャルネットワークとは、人と人が何らかの関係のもとで接続されているグラフデータのことを指し、研究者同士の共著関係や、Twitter・FacebookなどのSNSにおけるフォロー関係などがその代表例である。ソーシャルネットワークは多くの場合、各ノードは自身の特性を表現する属性値をもつ。研究者の共著ネットワークの場合は、研究者が発表した論文に含まれる単語などが例として挙げられ、Twitterの場合はツイートに含まれる単語やハッシュタグなどが挙げられる。ソーシャルネットワークは多くの場合、エッジ構造やノードの属性値が時間の経過とともに変化する。例えば時間の経過によって各ノードの興味関心が変わり、それによって属性値が変化したり、それに伴ってエッジが出現・消滅したりする。本研究では、このような動的に変化するソーシャルネットワークを対象に、これらの今後の変化を予測することを目的とする。時間の経過によるソーシャルネットワークの変化を分析・予測することで、市場規模の予測やソーシャルネットワークにおける人間関係の創発のメカニズムの解明への応用が期待できる。

動的に変化するネットワークの変化を予測する手法は近年活発に研究されており、ノードの潜在的な特徴に基づきネットワーク構造を予測する手法 [1], [11], [22] や、グラフニューラルネットワークを時系列グラフに拡張した手法 [4], [9], [26] などが近年提案されている。しかしながら、ネットワーク構造とノードの属性値のそれぞれの予測のみについて研究がほとんどであり、ネットワーク構造と属性値の変化の相互作用を利用した予測に関しては未だ十分な検討が行われていない。




図 1: 研究目的. 本研究の目的は、各ノードが属性を持つ動的なソーシャルネットワークにおける (1) グラフ構造の変化 (2) 各ノードの属性の変化の双方を予測することである。

本研究ではソーシャルネットワークの変化の予測を目的とし、(1) グラフ構造の変化と興味関心の変化の相互作用、(2) 友人関係を通じた興味関心の伝搬の二つに着目した予測モデルを提案する。ここで、本研究ではソーシャルネットワークの変化の予測を、未観測の時刻のエッジとノードの属性値の予測として定義する。本研究では潜在ベクトルに基づくネットワークの生成モデルを構成し、未観測の時刻の潜在ベクトルの変化の予測を通じて、未来のネットワークのエッジ構造とノードの属性値を予測する。

エッジおよび属性値の生成に関しては、ノードはネットワーク構造と興味関心のそれぞれに関する潜在的な特徴をもつと仮定し、これらを組み合わせることでエッジを生成するためのモデルを構築する。より具体的には、ノードがもつネットワーク構造の潜在的な特徴と、興味関心の潜在的な特徴のそれぞれの相関

とバイアスに基づいて生成されると仮定し、各ノードの属性値は興味関心の特性と、ある用語の特性の相関とバイアスに基づいて生成されると仮定する。

潜在ベクトルの予測に関しては、ネットワークを通じてノードの潜在ベクトルが伝搬すると仮定し、自らの潜在ベクトルの変化の傾向と、ネットワークを通じた潜在ベクトルを重み付けして足し合わせた値の変化の傾向に基づいた予測を行う。より具体的には、各ノードの潜在的特徴は、ソーシャルネットワークにおける友人の影響力と、個人の受容性にもとづいて変化させると仮定し、これらをモデルに組み込んだ予測モデルを提案する。さらに、属性値もノードからの影響を受けて変化すると仮定し、属性値自身の時間経過による変化と、関連するノードからの影響による特徴の変化を予測モデルに組み込む。これにより、ソーシャルネットワークの及び各ノードの興味関心の変化を同時に予測し、それらを相互に関連づけることによってネットワークの変化を予測する。本予測モデルはソーシャルネットワークが生成されるもっともらしさを最大化するように学習され、各個人の影響力と受容性およびモデル中の各パラメータはそれらの事前分布を考慮した MAP 推定により求める。

実験では生成データと実データを対象に本手法の有用性を検証した。生成データを用いた実験では、コミュニティの統合・分裂といった実際のソーシャルネットワークにおいて発生すると考えられるパターンを生成し、これらの変化を本手法により予測できるかを検証した。実データを用いた実験では *NIPS*, *DBLP* (研究者の共著者ネットワーク) と *Twitter* (ユーザ間のリツイートネットワーク) データセットを対象にし、ソーシャルネットワークの将来予測における本手法の有用性に関して検討を行った。実験の結果、提案手法は既存手法と比較してより高精度に未観測の時刻におけるネットワークの構造及びノードの属性値を予測できることを示した。

## 2 関連研究

動的に変化するネットワークデータに対する予測手法は様々なアプローチで提案されてきた。本節ではそれら関連研究を示すとともに、本研究との差異および本研究の位置づけに関して述べる。

### 2.1 ネットワークデータに対する表現学習

ネットワークデータに対する表現学習手法とは、ネットワーク構造をよく表現する潜在的ベクトルを学習するための手法であり、特に確率モデルに基づく潜在ベクトルモデル、ネットワークエンベディング、グラフニューラルネットワークといった文脈で近年様々な手法が提案されている。

確率モデルに基づくネットワークの表現学習手法として、潜在ベクトルに基づくリンク生成モデル [22], ノードが属するコミュニティにおけるエッジ生成とコミュニティ間のエッジ生成をモデル化した [1] などが提案されている。

ネットワークエンベディングとは、ネットワーク構造やノードがもつ属性値をできるだけよく保存するようにノードの

埋め込みを学習するための方法であり、代表的な手法として、ネットワーク構造を保存する手法の DeepWalk [24], LINE [25], Node2vec [6], コミュニティ構造とノードを同時にエンベディングする手法として、M-NMF [28], ComE [3], ネットワーク構造に加えてノードの属性に着目した手法として、ASNE [18] LANE [13], 動的に変化するネットワークに対するネットワークエンベディング手法として [29] などが存在する。より近年ではノードの変化と属性値の変化の双方を時系列的に埋め込む手法が提案されており、Twitter におけるユーザの関心の変化を追跡する手法 [19], テキスト情報を持つ動的なネットワークにおけるノードと単語のエンベディング手法 [14], 動的に変化する Attributed network におけるノードのエンベディング [18] などが提案されてきた。

より近年ではグラフニューラルネットワーク [15] を用いた表現学習手法が多く提案されており、グラフデータに対する変分オートエンコーダーの GVAE [16] や敵対的生成ネットワークを用いた GraphGAN [27] などが存在する。

これらの研究は観測済みのネットワークデータに対する手法で、本研究の目的である未観測の時刻におけるネットワークの状態の予測に関しては検討を行っていない。

### 2.2 ソーシャルネットワークの予測

ネットワーク構造から新規に生成されるノードの特徴量を予測する手法 GraphSAGE [10] ノードの潜在変数の変化をネットワーク構造における伝搬を考慮した上で予測する手法として LFP [11] が存在する。ノード集合の意見の群衆としての変化を予測する手法として CoNN [7], ノードの潜在変数の変化とコミュニティ構造の変化を抽出し、ネットワーク構造の補完を行う研究として ELSM [8] がある。リンク予測に対して構造情報と時間の情報を取り入れたネットワーク構造の予測手法として STEP [4], DyRep [26], VGRNN [9] が存在する。これらの研究ではネットワーク構造の変化の予測のみに着目しており、そのノードの属性値の予測は行っていないため、本研究とは目的が異なる。

ネットワーク構造から、ノードの特徴の変化を予測する手法 ONE-M [23] TensorCast [2] ユーザとアイテムの関係の履歴からそれぞれの特徴量の変化を予測し、ユーザとアイテムと今後のリンク関係をする手法として DeepCoevolve [5] や JODIE [17] が存在する。これらの手法は前述の手法とは異なり、ユーザとアイテムとの関係を予測する手法であり、本件研究とは目的が異なる。

本研究ではグラフ構造と属性値の変化の双方を対象にし、これらの相互作用と相関関係に着目したモデル化を行う点でこれらの既存研究とは異なる。

## 3 問題定義

本節では本研究で対象とする問題の厳密な定義について記述する。本研究では入力として離散的な時刻  $t = 1 \sim T$  における有向ソーシャルグラフ  $\mathcal{G}^{(t)} = (\mathcal{V}^{(t)}, \mathcal{E}^{(t)})$  と、各ノード  $u \in \mathcal{V}$




図 2: エッジ及び属性値の生成モデル. 各ノードはネットワーク構造を表現する潜在ベクトル  $\mathbf{u}_{i \rightarrow}^{(t)}$ ,  $\mathbf{u}_{\rightarrow j}^{(t)}$  と興味関心を表現する潜在ベクトル  $\mathbf{v}_{i \rightarrow}^{(t)}$ ,  $\mathbf{v}_{\rightarrow j}^{(t)}$  をもち, 各属性値も潜在ベクトル  $\mathbf{x}_i^{(t)}$  をもつ. エッジはネットワーク構造および興味関心の相関に基づいて生成され, 属性値はノードの興味関心の潜在ベクトルと属性値の潜在ベクトルとの相関に基づいて生成される.

がもつ関心を表す二部グラフ  $\mathcal{A}^{(t)} = (\mathcal{V}^{(t)}, \mathcal{X}^{(t)}, \mathcal{Y}^{(t)})$  が与えられるとする. ここで  $\mathcal{V}^{(t)}$  はノード集合,  $\mathcal{X}^{(t)}$  は属性値集合,  $\mathcal{E}^{(t)}$  はノード間のエッジ集合,  $\mathcal{Y}^{(t)}$  は二部グラフにおけるノードと属性値間のエッジである. 時刻  $t$  に  $u$  から  $v$  にエッジが存在することを  $e_{u \rightarrow v}^{(t)} \in \mathcal{E}^{(t)}$ ,  $u$  が  $x$  に対して関心を持つことを  $y_{u \rightarrow x}^{(t)} \in \mathcal{Y}^{(t)}$  と表現する. ここで, 本研究では特に人と人との関係性をあらかずソーシャルネットワークを対象に検討をおこなうため, ソーシャルグラフのノードは人物を表し, 属性値は単語や Twitter におけるハッシュタグなどに対応する. 本研究の目的は, 時刻  $t' > T$  におけるソーシャルグラフ  $\mathcal{G}^{(t')}$  と関心を表す二部グラフ  $\mathcal{A}^{(t')}$  を予測することである. 本研究では, 新規ノード・単語の出現および消滅は考慮せず, 既存のノード  $i, j$  間に存在するエッジの存在確率  $P(e_{i \rightarrow j}^{(t')} \in \mathcal{E}^{(t')})$  および  $P(y_{i \rightarrow x}^{(t')} \in \mathcal{Y}^{(t')})$  を予測する.

## 4 提案手法

本節では, 本論文で提案する未来のソーシャルネットワークを予測するためのモデルに関して記述する. 提案手法は, (1) 潜在ベクトルの相関に基づくネットワーク生成モデル, (2) 未来の潜在ベクトルを予測するための生成モデルから構成される. 学習データから各時刻の潜在ベクトル, ネットワーク生成および未来の潜在ベクトルを予測するためのモデルパラメータを学習し, それらを用いて未来の潜在ベクトルを予測し, ネットワーク生成モデルに入力することで未来のソーシャルネットワークにおけるエッジの生成確率を予測する. 以下の節ではそれぞれの構成要素について記述する.

### 4.1 潜在ベクトルの相関に基づくネットワーク生成モデル

提案手法では, (1) ネットワークの構造的な特徴が類似している. (2) 興味関心が類似している. という二つの条件を満たす

表 1: 主な記号と定義

記号	定義
$\mathcal{G}^{(t)} = (\mathcal{V}^{(t)}, \mathcal{E}^{(t)})$	時刻 $t$ におけるグラフ
$\mathcal{A}^{(t)} = (\mathcal{V}^{(t)}, \mathcal{X}^{(t)}, \mathcal{Y}^{(t)})$	時刻 $t$ における属性グラフ
$\mathcal{V}^{(t)} = \{i\}$	時刻 $t$ におけるノード集合
$\mathcal{E}^{(t)} = \{e_{i \rightarrow j}^{(t)}\}$	時刻 $t$ におけるエッジ集合
$e_{i \rightarrow j}^{(t)} = (i, j)$	$i$ から $j$ への有向エッジ
$\mathcal{X}^{(t)} = \{x\}$	時刻 $t$ における属性値集合
$\mathcal{Y}^{(t)} = \{y_{i \rightarrow x}^{(t)}\}$	時刻 $t$ における属性エッジ集合
$y_{i \rightarrow x}^{(t)} = (i, x)$	$i$ から $x$ への属性エッジ
$\mathbf{U} = \{\mathbf{U}^{(t)}\}$ ( $\mathbf{U}^{(t)} = \{\mathbf{u}_i^{(t)}\}$ )	エッジ構造ベクトル
$\mathbf{V} = \{\mathbf{V}^{(t)}\}$ ( $\mathbf{V}^{(t)} = \{\mathbf{v}_i^{(t)}\}$ )	興味関心ベクトル
$\mathbf{X} = \{\mathbf{X}^{(t)}\}$ ( $\mathbf{X}^{(t)} = \{\mathbf{x}_i^{(t)}\}$ )	属性値潜在ベクトル
$\Theta = \{\Theta_{\mathcal{E}}, \Theta_{\mathcal{Y}}, \Theta_u, \Theta_v, \Theta_x\}$	全モデルパラメータ
$\Theta_{\mathcal{E}} = \{\mathbf{R}_{\mathcal{E}1}, \mathbf{R}_{\mathcal{E}2}, b_{\mathcal{E}}\}$	エッジ生成パラメータ
$\Theta_{\mathcal{Y}} = \{\mathbf{R}_{\mathcal{Y}}, b_{\mathcal{E}}\}$	属性生成パラメータ
$\Theta_u = \{\mathbf{W}_1, \mathbf{W}_2, \mathbf{b}, \{m_i\}, \{w_i\}\}$	エッジ構造予測パラメータ
$\Theta_v = \{\mathbf{W}_1, \mathbf{W}_2, \mathbf{b}, \{m_i\}, \{w_i\}\}$	興味関心予測パラメータ
$\Theta_x = \{\mathbf{W}_1, \mathbf{W}_2, \mathbf{b}, \{q_x\}, \{r_i\}\}$	属性値予測パラメータ

すときに, ノード間にエッジが張られると仮定する. これは類似した特性を持つ人間には人間関係が発生しやすいという homophily [21] 現象と, 友人の友人は友人になりやすいという transitivity [12] といった, ソーシャルネットワークの構造特性を捉えることを狙いとしている.

本研究では各ノードにおける (1) ネットワークの構造的な特徴と (2) 興味関心の特徴を, 潜在ベクトルによって表現する. ノード  $i$  のネットワークにおける構造の特徴の潜在ベクトルを  $\mathbf{u}_i$ , 興味関心の特徴を表す潜在ベクトルを  $\mathbf{v}_i$  とする. ここで, エッジの発信側としての特徴を  $\mathbf{u}_{i \rightarrow}^{(t)} \in \mathbb{R}^{k_1}$ ,  $\mathbf{v}_{i \rightarrow}^{(t)} \in \mathbb{R}^{k_2}$ , エッジの受信側としての特徴を  $\mathbf{u}_{\rightarrow i}^{(t)} \in \mathbb{R}^{k_1}$ ,  $\mathbf{v}_{\rightarrow i}^{(t)} \in \mathbb{R}^{k_2}$  とし, これらを結合したベクトルを  $\mathbf{u}_i^{(t)} = \mathbf{u}_{i \rightarrow}^{(t)} \oplus \mathbf{u}_{\rightarrow i}^{(t)} \in \mathbb{R}^{2k_1}$ ,  $\mathbf{v}_i^{(t)} = \mathbf{v}_{i \rightarrow}^{(t)} \oplus \mathbf{v}_{\rightarrow i}^{(t)} \in \mathbb{R}^{2k_2}$  と表記する. また, 属性値の潜在ベクトルを  $\mathbf{x}_j^{(t)} \in \mathbb{R}^{k_2}$  とする. すべての時間における潜在ベクトルの集合をそれぞれ  $\mathbf{U} = \{\mathbf{U}^{(t)}\}_{t \in T}$ ,  $\mathbf{V} = \{\mathbf{V}^{(t)}\}_{t \in T}$ ,  $\mathbf{X} = \{\mathbf{X}^{(t)}\}_{t \in T}$  と表現する.

これらを用い, エッジ  $e_{i \rightarrow j}^{(t)}$  が生成される確率は以下の式に基づいて計算する.

$$P(e_{i \rightarrow j}^{(t)} \in \mathcal{E}^{(t)} | \Theta_{\mathcal{E}}) = \sigma \left( \mathbf{u}_{i \rightarrow}^{(t)\top} \mathbf{R}_{\mathcal{E}1} \mathbf{u}_{\rightarrow j}^{(t)} + \mathbf{v}_{i \rightarrow}^{(t)\top} \mathbf{R}_{\mathcal{E}2} \mathbf{v}_{\rightarrow j}^{(t)} + b_{\mathcal{E}} \right) \quad (1)$$

ここで,  $\mathbf{R}_{\mathcal{E}1}, \mathbf{R}_{\mathcal{E}2}$  は潜在ベクトルの相関を表す行列,  $b_{\mathcal{E}}$  はエッジ生成のためのバイアス項,  $\sigma$  はシグモイド関数  $\sigma(x) = \frac{1}{1 + \exp(-x)}$  である.  $\Theta_{\mathcal{E}} = \{\mathbf{R}_{\mathcal{E}1}, \mathbf{R}_{\mathcal{E}2}, b_{\mathcal{E}}\}$  はエッジ生成のためのパラメータ集合で, すべての時刻において共通のパラメータを用いるものとする. 同様に, あるノード  $i \in \mathcal{V}$  の属性値  $x \in \mathcal{X}$  の生成確率は以下で求める.

$$P(y_{i \rightarrow j}^{(t)} \in \mathcal{Y}^{(t)} | \Theta_{\mathcal{Y}}) = \sigma \left( \mathbf{v}_i^{(t)\top} \mathbf{R}_{\mathcal{Y}} \mathbf{x}_j^{(t)} + b_{\mathcal{Y}} \right) \quad (2)$$

ここでも, ノードの潜在ベクトルと属性値の潜在ベクトルとの相関が大きいほどエッジが生成される確率が大きくなる. これらを踏まえ, すべての時刻  $t = 1 \sim T$  におけるソーシャルグラフの生成確率に対する対数尤度関数は以下のようになる.

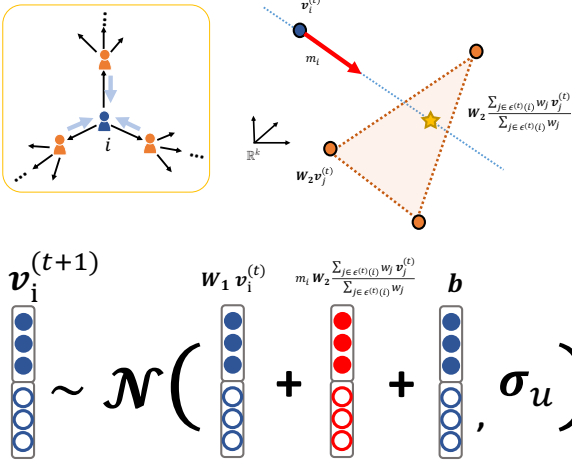


図 3: 潜在ベクトルの伝搬. 黄色枠で囲まれたようなグラフが与えられたとき, あるノード  $i$  の潜在ベクトルは, そのノードが接続するノードの潜在ベクトルの重みに対して線形変換を施したベクトルの重み付き線形和の方向に対して変化が生じる. ここで各ノードの影響力  $w_j$  が大きいほどそのノードに対応するベクトルの影響が大きくなり, ノード  $i$  の受容性  $m_i$  が大きいほど, 隣接ノードからの潜在ベクトルの伝搬による影響が大きくなる.

$$\begin{aligned} \mathcal{L}_{\mathcal{E}} &= \log \prod_{t=1}^T P(\mathcal{E}^{(t)} | \mathbf{U}^{(t)}, \mathbf{V}^{(t)}, \Theta_{\mathcal{E}}) \\ &= \sum_{t=1}^T \sum_{e_{i \rightarrow j}^{(t)} \in \mathcal{E}^{(t)}} \log P(e_{i \rightarrow j}^{(t)} \in \mathcal{E}^{(t)} | \Theta_{\mathcal{E}}) \\ &\quad + \sum_{t=1}^T \sum_{e_{i \rightarrow j}^{(t)} \notin \mathcal{E}^{(t)}} \log \left( 1 - P(e_{i \rightarrow j}^{(t)} \in \mathcal{E}^{(t)} | \Theta_{\mathcal{E}}) \right) \end{aligned} \quad (3)$$

$$\begin{aligned} \mathcal{L}_{\mathcal{Y}} &= \log \prod_{t=1}^T P(\mathcal{Y}^{(t)} | \mathbf{V}^{(t)}, \mathbf{X}^{(t)}, \Theta_{\mathcal{Y}}) \\ &= \sum_{t=1}^T \sum_{y_{i \rightarrow x}^{(t)} \in \mathcal{Y}^{(t)}} \log P(y_{i \rightarrow x}^{(t)} \in \mathcal{Y}^{(t)} | \Theta_{\mathcal{Y}}) \\ &\quad + \sum_{t=1}^T \sum_{y_{i \rightarrow x}^{(t)} \notin \mathcal{Y}^{(t)}} \log \left( 1 - P(y_{i \rightarrow x}^{(t)} \in \mathcal{Y}^{(t)} | \Theta_{\mathcal{Y}}) \right) \end{aligned} \quad (4)$$

## 4.2 未来の潜在ベクトルの生成モデル

ここでは, ネットワークを通じた潜在ベクトルの伝搬を考慮することによる, 未来の潜在ベクトルの生成モデルについて記述する. 本研究では各ノードの影響力と受容性をそれぞれモデル化し, これらを考慮した未来の潜在ベクトルの生成を行う. 各ノードの影響力が大きいほど, 他のノードの潜在ベクトルの変化に対する影響力が大きくなり, 受容性が大きいほど, 自身の潜在ベクトルを変化させる際に他のノードの潜在ベクトルの影響を強く受けるというモデル化がなされる.

本研究では各潜在ベクトルの変化の確率分布を以下の式で定義する.

$$P(\mathbf{u}_i^{(t)} | \mathbf{U}^{(t-1)}, \Theta_u) = \mathcal{N}(\mathbf{u}_i^{(t)}; \boldsymbol{\mu}_u^{(t)}, \sigma_u \mathbf{I}), \quad (7)$$

$$\boldsymbol{\mu}_u^{(t)} = \mathbf{W}_1 \mathbf{u}_i^{(t-1)} + m_i \mathbf{W}_2 \frac{\sum_{j \in \mathcal{E}^{(t)}(i)} w_j \mathbf{u}_j^{(t-1)}}{\sum_{j \in \mathcal{E}^{(t)}(i)} w_j} + \mathbf{b}$$

$$P(\mathbf{v}_i^{(t)} | \mathbf{V}^{(t-1)}, \Theta_v) = \mathcal{N}(\mathbf{v}_i^{(t)}; \boldsymbol{\mu}_v^{(t)}, \sigma_v \mathbf{I}), \quad (8)$$

$$\boldsymbol{\mu}_v^{(t)} = \mathbf{W}_1 \mathbf{v}_i^{(t-1)} + m_i \mathbf{W}_2 \frac{\sum_{j \in \mathcal{E}^{(t)}(i)} w_j \mathbf{v}_j^{(t-1)}}{\sum_{j \in \mathcal{E}^{(t)}(i)} w_j} + \mathbf{b}$$

ここで,  $w_i \in \mathbb{R}^+$  はノード  $i$  の影響力の大きさを,  $m_i \in \mathbb{R}^+$  はノード  $i$  の受容性の大きさを示している.  $\mathcal{E}^{(t)}(i)$  は時刻  $t$  においてノード  $i$  が接続しているノードの集合であり,  $\mathcal{E}^{(t)}(i) = \{j | e_{i \rightarrow j}^{(t)} \in \mathcal{E}^{(t)}\}$  である. 上記予測モデルの第一項は潜在ベクトル自身の時間経過による変化を表しており, 第二項はネットワーク中で接続する他のノードからの影響を考慮した時間経過による変化を表している. これらに基づく特徴量の変化を線形変換と非線形関数による変換によって, 未来の潜在ベクトルの状態を予測する. ここで,  $\sigma_u, \sigma_v$  はハイパラメータであり, その他変数および行列は学習データから推定する.

同様に, 属性値の潜在ベクトルの変化は,

$$P(\mathbf{x}_i^{(t)} | \mathbf{V}^{(t-1)}, \mathbf{X}^{(t-1)}, \Theta_x) = \mathcal{N}(\mathbf{x}_i^{(t)}; \boldsymbol{\mu}_x^{(t)}, \sigma_x \mathbf{I}) \quad (9)$$

$$\boldsymbol{\mu}_x^{(t)} = \mathbf{W}_1 \mathbf{x}_i^{(t-1)} + q_i \mathbf{W}_2 \frac{\sum_{j \in \mathcal{Y}^{(t)}(x)} r_j \mathbf{v}_j^{(t-1)}}{\sum_{j \in \mathcal{Y}^{(t)}(x)} r_j} + \mathbf{b}$$

とする. ここで,  $\mathcal{Y}^{(t)}(x)$  は時刻  $t$  において属性値  $x$  をもつノード集合であり,  $\mathcal{Y}^{(t)}(x) = \{i | y_{i \rightarrow x}^{(t)} \in \mathcal{Y}^{(t)}\}$  である.

時間経過による潜在ベクトルの変化に関する対数尤度関数は以下で表される.

$$\mathcal{L}_{\Delta u}^{(t)} = \log \prod_{i \in \mathcal{V}} P(\mathbf{u}_i^{(t)} | \mathbf{U}^{(t-1)}, \Theta_u) \quad (10)$$

$$= \log \prod_{i \in \mathcal{V}} \mathcal{N}(\mathbf{u}_i^{(t)}; \boldsymbol{\mu}_u^{(t)}, \sigma_u \mathbf{I}) \quad (11)$$

$$= - \sum_{i \in \mathcal{V}} \frac{1}{2\sigma_u} \|\mathbf{u}_i^{(t)} - \boldsymbol{\mu}_u^{(t)}\|_2^2 + \text{const.} \quad (12)$$

同様に,

$$\mathcal{L}_{\Delta v}^{(t)} = \log \prod_{i \in \mathcal{V}} P(\mathbf{v}_i^{(t)} | \mathbf{V}^{(t-1)}, \Theta_v) \quad (13)$$

$$= - \sum_{i \in \mathcal{V}} \frac{1}{2\sigma_v} \|\mathbf{v}_i^{(t)} - \boldsymbol{\mu}_v^{(t)}\|_2^2 + \text{const.} \quad (14)$$

$$\mathcal{L}_{\Delta x}^{(t)} = \log \prod_{i \in \mathcal{X}} P(\mathbf{x}_i^{(t)} | \mathbf{X}^{(t-1)}, \mathbf{V}^{(t-1)}, \Theta_x) \quad (15)$$

$$= - \sum_{i \in \mathcal{X}} \frac{1}{2\sigma_x} \|\mathbf{x}_i^{(t)} - \boldsymbol{\mu}_x^{(t)}\|_2^2 + \text{const.} \quad (16)$$

## 4.3 学 習

本節では, 予測モデルのパラメータ学習について記述する. 予測モデルのパラメータは出力されるソーシャルネットワークの出現確率が最大化されるように学習する. ここで, 本研究では事前分布を考慮した MAP 推定によりパラメータを推定す






図 4: ネットワーク生成過程のグラフィカルモデル. 各時刻のネットワークはその時刻の潜在ベクトルから生成され, 次の時刻の潜在ベクトルはその時刻の潜在ベクトルと, 新しく生成されたネットワークを通じた伝搬によって生成される.

る. ベイズの定理および潜在ベクトルの依存関係 (図 4) に基づき変数を分離すると以下のように変形できる.

$$\mathbf{U}, \mathbf{V}, \mathbf{X}, \Theta$$

$$= \arg \max_{\mathbf{U}, \mathbf{V}, \mathbf{X}, \Theta} P(\mathbf{U}, \mathbf{V}, \mathbf{X} | \{\mathcal{E}^{(t)}, \mathcal{Y}^{(t)}\}_{t \in 1 \dots T}, \Theta) \quad (17)$$

$$= \arg \max_{\mathbf{U}, \mathbf{V}, \mathbf{X}, \Theta} P(\mathbf{U}, \mathbf{V}, \mathbf{X}, \{\mathcal{E}^{(t)}, \mathcal{Y}^{(t)}\}_{t \in 1 \dots T} | \Theta) \quad (18)$$

$$= \arg \max_{\mathbf{U}, \mathbf{V}, \mathbf{X}, \Theta} \log P(\mathbf{U}^{(1)}) + \log P(\mathbf{V}^{(1)}) + \log P(\mathbf{X}^{(1)})$$

$$+ \sum_{t=1}^T \log P(\mathcal{E}^{(t)} | \mathbf{U}^{(t)}, \mathbf{V}^{(t)}, \Theta_{\mathcal{E}})$$

$$+ \log P(\mathcal{Y}^{(t)} | \mathbf{V}^{(t)}, \mathbf{X}^{(t)}, \Theta_{\mathcal{Y}})$$

$$+ \sum_{t=2}^T \log P(\mathbf{U}^{(t)} | \mathbf{U}^{(t-1)}, \Theta_u)$$

$$+ \log P(\mathbf{V}^{(t)} | \mathbf{V}^{(t-1)}, \Theta_v)$$

$$+ \log P(\mathbf{X}^{(t)} | \mathbf{V}^{(t-1)}, \mathbf{X}^{(t-1)}, \Theta_x) \quad (19)$$

$$= \arg \max_{\mathbf{U}, \mathbf{V}, \mathbf{X}, \Theta} \mathcal{R} + \mathcal{L}_{\mathcal{E}} + \mathcal{L}_{\mathcal{Y}} + \sum_{t=2}^T \mathcal{L}_{\Delta_u}^{(t)} + \mathcal{L}_{\Delta_v}^{(t)} + \mathcal{L}_{\Delta_x}^{(t)}. \quad (20)$$

本研究ではこの損失関数を勾配降下法に基づいて最大化する. ここで,

$$\mathcal{R} = \log P(\mathbf{U}^{(1)}) + \log P(\mathbf{V}^{(1)}) + \log P(\mathbf{X}^{(1)}) \quad (21)$$

$$= \log \prod_{i \in \mathcal{V}} \mathcal{N}(\mathbf{u}_i^{(1)}; \mathbf{0}, \sigma_u \mathbf{I}) + \log \prod_{i \in \mathcal{V}} \mathcal{N}(\mathbf{v}_i^{(1)}; \mathbf{0}, \sigma_v \mathbf{I})$$

$$+ \log \prod_{i \in \mathcal{X}} \mathcal{N}(\mathbf{x}_i^{(1)}; \mathbf{0}, \sigma_x \mathbf{I}) \quad (22)$$

$$= \sum_{i \in \mathcal{V}} \frac{1}{2\sigma_x} \|\mathbf{u}_i^{(1)}\|_2^2 + \sum_{i \in \mathcal{V}} \frac{1}{2\sigma_u} \|\mathbf{v}_i^{(1)}\|_2^2$$

$$+ \sum_{i \in \mathcal{X}} \frac{1}{2\sigma_x} \|\mathbf{x}_i^{(1)}\|_2^2 + Const. \quad (23)$$

であり, 各潜在ベクトルに対する正則化項の役割をする.

#### 4.4 将来予測

学習データから求めたモデルのパラメータを用いて未来のソーシャルネットワークを予測する. 本手法では, ソーシャルネットワークの生成と潜在ベクトルの予測を交互に行うことで, 複数ステップ先のソーシャルネットワークにおけるエッジを予測する. より具体的には各ノード及び用語の潜在ベクトルの変化を求め, その潜在ベクトルから未知の時間におけるノード間のエッジ及びエッジと用語との関係が生成される確率を求める. 潜在ベクトルの変化は以下の等式により求める.

$$\mathbf{u}_i^{(t+1)} = \mathbf{W}_1 \mathbf{u}_i^{(t)} + m_i \mathbf{W}_2 \frac{\sum_{j \in \mathcal{E}^{(t)}(i)} w_j \mathbf{u}_j^{(t)}}{\sum_{j \in \mathcal{E}^{(t)}(i)} w_j} + \mathbf{b} \quad (24)$$

ここでパラメータ  $\mathbf{W}_1, \mathbf{W}_2, \mathbf{b}, \{w_i, m_i\}_{i \in \mathcal{V}}$  は学習データから最適化したパラメータを用いる.  $\mathbf{V}^{(t)}$  および  $\mathbf{X}^{(t)}$  に関しても同様に求める.

### 5 合成データを用いた実験

ここでは合成データに対して本手法を適用することにより, 手法の特性を検証する. 本実験では, 密に接続された2つのコミュニティが徐々に統合していく場合のデータと, 徐々に分裂していく場合の2つのデータを合成する. ここではノード数は20, 属性は「赤」と「青」の2つとして実験した.

統合していく場合のデータは以下のような手順で生成した. (1) 2つの非連結なクリークを生成し, それぞれの連結成分が「赤」と「青」をもつように設定する. (2) 2つのクリーク間に一定確率  $p$  でエッジを張る. (3) 時刻  $t$  における隣接行列を  $\mathbf{A}^{(t)}$ , 属性との関係行列を  $\mathbf{T}^{(t)}$  とし, 以下の更新式で次の時刻のグラフを生成する.

$$\mathbf{A}^{(t+1)} = \min([\mathbf{A}^{(t)} + \epsilon \mathbf{A}^{(t)\top} \mathbf{A}^{(t)}, \mathbf{1}] \quad (25)$$

$$\mathbf{T}^{(t+1)} = \min([\mathbf{T}^{(t)} + \epsilon \mathbf{A}^{(t)\top} \mathbf{T}^{(t)}, \mathbf{1}] \quad (26)$$

ここで,  $[\cdot]$  は床関数であり, 行列の各要素に適用する. 本実験では  $p = 0.1$  とし,  $\epsilon = 0.5$  とした

分裂していく場合のデータは以下の手順で生成した. (1) 統合する場合と同様に2つの非連結なクリークを生成し, 一定確率のもとで, 2つのクリークに存在するノード間にエッジを生成する. (2) 時刻をひとつ進めるたびに, クリーク間にあるエッジを一定確率で消失させる.

図5は合成データセットに対して提案手法を適用した際の予測結果である. 図(a)(b)において, 左3つのグラフが学習データ, 右2つのグラフが予測結果である. これらの図をみると, 提案手法はコミュニティの統合, 分裂および属性の伝播の様子を予測できていることがわかる.

### 6 実データを用いた実験

本節では, 実データを用いて本提案手法がどれだけ正確にネットワークを予測できるかを検証する. 本実験では, 提案手法において潜在ベクトルを更新しない場合の手法をベースライ

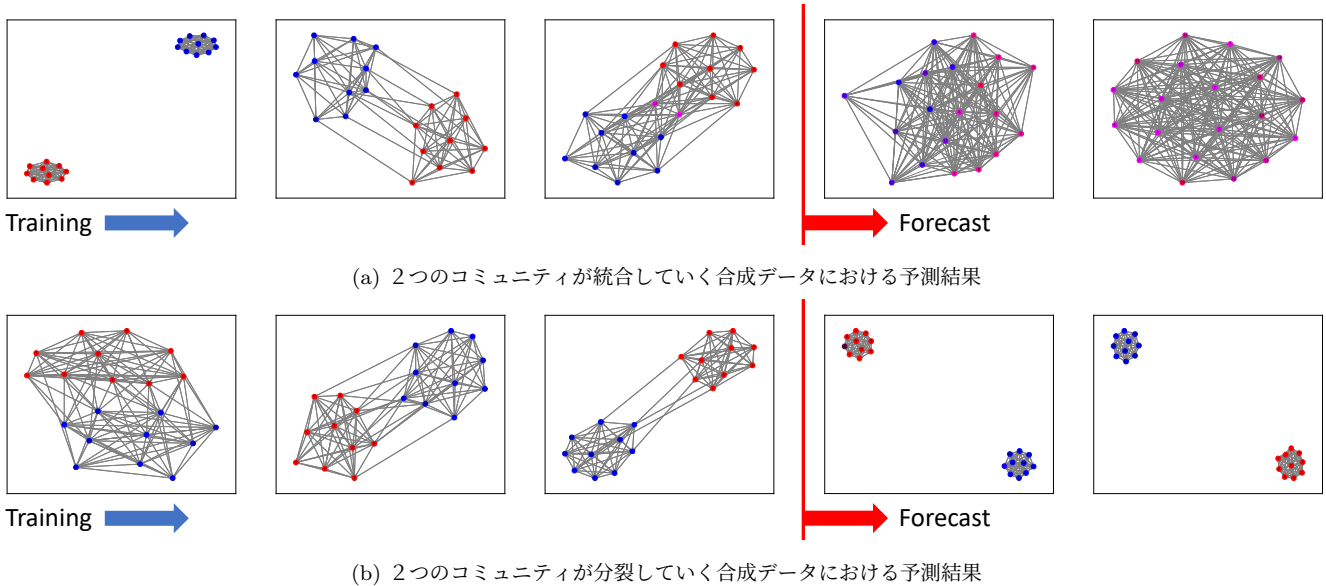


図 5: 合成データに対する予測結果: 図 (a), 図 (b) はそれぞれ2つのコミュニティが統合, 分裂していく生成データセットに対して提案手法を適用した際の予測結果を示した図である. ノードの色はそのノードがもつ属性値を表しており, ここでは「青」と「赤」の2つの属性が存在する.「紫」は両方の属性をもつことを示している. これらの図を見ると, 提案手法は, コミュニティの統合, 分裂のパターンをもっともらしく予測できることがわかる.

ン手法として用い, 用いた場合の予測モデルと比較することで提案手法の有効性を検証する. 以下の節では実験に用いたデータセットの説明および得られた予測結果について述べる.

を論文では, 比較手法として, 提案手法のエッジの潜在ベクトルに対して Recurrent Neural Network (RNN) を適用したモデルとして *RNN edge*, 興味関心の潜在ベクトルと属性値の潜在ベクトルに対して RNN を適用した手法として *RNN attr*, すべての潜在ベクトルに対して RNN を適用した *RNN both*, およびエッジを生成するグラフニューラルネットワークに基づく手法として Variational Graph Auto-Encoder (VGAE) [16], VGRNN [9] を採用する.

## 6.1 データセット

データセットとして *NIPS*, *DBLP*, *Twitter* を用いる. 以下にそれぞれのデータセットの収集, 作成方法を記述する.

*NIPS* は研究者の共著者ネットワークである. ノードは著者, エッジは共著関係, 時間区分は年単位である. ある年に二人の著者  $u, v$  が共著論文を発表したとき, その二人の著者間に双方向の有向エッジが張られる. 各ノードはある年に発表した論文のタイトルに含まれる単語を属性値としてもつ. 2008年から2017年に発表された機械学習分野の7国際会議の論文データを取得し, 2008年から2012年までを学習データ, 2013年から2017年までをテストデータとして用いる. 前処理として各単語はステミング処理を行い, 全時間区分に出現しない著者はデータセットから除外した. ノード数は32で, 属性値数は2411である.

*DBLP* は研究者の共著者ネットワークである. ネットワークデータは *NIPS* と同様の方法で作成した. 2008年から2017年に発表されたデータマイニング, データベース, 自然言語処


理, 機械学習, 人工知能, 情報検索, コンピュータビジョンから構成されるの47国際会議の論文データを取得し, 2008年から2012年までを学習データ, 2013年から2017年までをテストデータとして用いる. ノード数は500で, 属性値数は3854である.

*Twitter* はユーザ間のリツイートネットワークであり, 時間区分は月単位である. ノードはユーザで, ある月にユーザ  $u$  のツイートを他のユーザ  $v$  がリツイートした際に  $u$  から  $v$  に対して有向エッジが張られる. 各ユーザは各時間区分のツイートに含まれていたハッシュタグを属性値としてもつ. 収集期間は2010年1月から2010年10月までで, 学習データとして1月から5月, テストデータとして6月から10月までのデータを用いた[20]. ここで, すべての時間区分を通じて一度しか出現しなかったユーザはデータセットから除外した. ノード数は234305で, 属性値数は5372である.


## 6.2 実験結果

本研究では予測精度の検証に NLL (Negative Log-Likelihood) と AUC (Area Under Curve) を用いた. NLL は低いほど予測対象をよリモっともらしく生成したことを示しており, AUC は高いほどより正確にエッジおよび属性値の出現を予測できていることを示している.


図 6, 図 7 はそれぞれ各予測時刻における負の対数尤度, AUC の値の変化を示している. 図を見ると, 提案手法 (青色の線) はほぼすべての時間において既存手法 (橙色の線) と比較してより正確にネットワークを予測していることがわかる. また, ベースライン手法は, 時間の経過とともに NLL が上昇し AUC が減少する傾向にある一方で, 提案手法は時間が経過しても精度が低下していないことが図から確認できる.




(a) NIPS: エッジの NLL




(b) DBLP: エッジの NLL




(c) Twitter: エッジの NLL



(d) NIPS: 属性値の NLL




(e) DBLP: 属性値の NLL




(f) Twitter: 属性値の NLL


図 6: 予測を行った時刻と負の対数尤度 (Negative Log-Likelihood): 値が低いほど、よりもっともらしくネットワークを生成していることを示す。横軸は予測を行った時刻で縦軸は NLL である。提案手法 (青色) はほぼすべての時刻において、ベースライン手法と比較してよりもっともらしいネットワークを生成していることがわかる。




(a) NIPS: エッジの AUC




(b) DBLP: エッジの AUC




(c) Twitter: エッジの AUC



(d) NIPS: 属性値の AUC



(e) DBLP: 属性値の AUC



(f) Twitter: 属性値の AUC

図 7: 予測を行った時刻と AUC (Area Under Curve): 値が高いほど、より正確にネットワークを生成していることを示す。横軸は予測を行った時刻で縦軸は AUC である。提案手法 (青色) はほぼすべての時刻において、ベースライン手法と比較してよりもっともらしいネットワークを生成していることがわかる。

## 7 まとめ

本研究ではソーシャルネットワークの時間経過による変化を予測する手法を提案した。提案モデルはノード間のエッジと、ノードと属性値との関係性の二部グラフのエッジの生成モデル

として振る舞い、これらが生成される確率を最大化するようにパラメータを学習する。本研究における予測モデルはネットワーク生成のためのモデルと、各ノードおよび属性値の潜在ベクトルの変化の予測モデルから構成される。ネットワークの生成モデルは、潜在ベクトルの相関とバイアスに基づいてエッ

ジの生成確率を決定する。潜在ベクトルの予測モデルは、あるノードの自発的な興味関心の変化と、ネットワーク中で隣接するノード、および属性値から潜在ベクトルの伝搬に基づいて、新しい時刻における潜在ベクトルを生成すると仮定し、これらを考慮した予測モデルを構成した。生成データを用いた実験より、コミュニティの統合・分裂というソーシャルネットワークの変化を予測できることを示した。実データを用いた実験より、提案手法はベースライン手法と比較して、未観測の時刻における実際のソーシャルネットワークをより正確に予測できることを示した。

今後の展望としては、本論文では離散的な時間における予測モデルを構築したが、連続的な時間における予測モデルについて今後検討を行うことを計画している。

## 謝 辞

本研究は JSPS 科研費 20K23337 の支援を受けたものです。

## 文 献

- [1] E. M. Airoldi, D. M. Blei, S. E. Fienberg, and E. P. Xing. Mixed membership stochastic blockmodels. *Journal of machine learning research*, 9(Sep):1981–2014, 2008.
- [2] M. Araújo, P. Ribeiro, and C. Faloutsos. Tensorcast: forecasting time-evolving networks with contextual information. In *Proceedings of the 27th International Joint Conference on Artificial Intelligence*, pp. 5199–5203, 2018.
- [3] S. Cavallari, V. W. Zheng, H. Cai, K. C.-C. Chang, and E. Cambria. Learning community embedding with community detection and node embedding on graphs. In *Proceedings of the 2017 ACM on Conference on Information and Knowledge Management*, pp. 377–386, 2017.
- [4] H. Chen and J. Li. Exploiting structural and temporal evolution in dynamic link prediction. In *Proceedings of the 27th ACM International Conference on Information and Knowledge Management*, pp. 427–436, 2018.
- [5] H. Dai, Y. Wang, R. Trivedi, and L. Song. Deep coevolutionary network: Embedding user and item features for recommendation. *arXiv preprint arXiv:1609.03675*, 2016.
- [6] A. Grover and J. Leskovec. node2vec: Scalable feature learning for networks. In *Proceedings of the 22nd ACM SIGKDD international conference on Knowledge discovery and data mining*, pp. 855–864, 2016.
- [7] Y. Gu, Y. Sun, and J. Gao. The co-evolution model for social network evolving and opinion migration. In *Proceedings of the 23rd ACM SIGKDD international conference on knowledge discovery and data mining*, pp. 175–184, 2017.
- [8] S. Gupta, G. Sharma, and A. Dukkipati. A generative model for dynamic networks with applications. In *Proceedings of the AAAI Conference on Artificial Intelligence*, Vol. 33, pp. 7842–7849, 2019.
- [9] E. Hajiramezanali, A. Hasanzadeh, N. Duffield, K. R. Narayanan, M. Zhou, and X. Qian. Variational graph recurrent neural networks. *arXiv preprint arXiv:1908.09710*, 2019.
- [10] W. Hamilton, Z. Ying, and J. Leskovec. Inductive representation learning on large graphs. In *Advances in neural information processing systems*, pp. 1024–1034, 2017.
- [11] C. Heaulani and Z. Ghahramani. Dynamic probabilistic models for latent feature propagation in social networks. In *International Conference on Machine Learning*, pp. 275–283, 2013.
- [12] P. W. Holland and S. Leinhardt. A dynamic model for social networks. *Journal of Mathematical Sociology*, 5(1):5–20, 1977.
- [13] X. Huang, J. Li, and X. Hu. Label informed attributed network embedding. In *Proceedings of the Tenth ACM International Conference on Web Search and Data Mining*, pp. 731–739, 2017.
- [14] H. Ito, T. Komamizu, T. Amagasa, and H. Kitagawa. Network-word embedding for dynamic text attributed networks. In *2018 IEEE 12th International Conference on Semantic Computing (ICSC)*, pp. 334–339. IEEE, 2018.
- [15] T. N. Kipf and M. Welling. Semi-supervised classification with graph convolutional networks. *arXiv preprint arXiv:1609.02907*, 2016.
- [16] T. N. Kipf and M. Welling. Variational graph auto-encoders. *arXiv preprint arXiv:1611.07308*, 2016.
- [17] S. Kumar, X. Zhang, and J. Leskovec. Predicting dynamic embedding trajectory in temporal interaction networks. In *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, pp. 1269–1278, 2019.
- [18] J. Li, H. Dani, X. Hu, J. Tang, Y. Chang, and H. Liu. Attributed network embedding for learning in a dynamic environment. In *Proceedings of the 2017 ACM on Conference on Information and Knowledge Management*, pp. 387–396, 2017.
- [19] S. Liang, X. Zhang, Z. Ren, and E. Kanoulas. Dynamic embeddings for user profiling in twitter. In *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, pp. 1764–1773, 2018.
- [20] T. Lou, J. Tang, J. Hopcroft, Z. Fang, and X. Ding. Learning to predict reciprocity and triadic closure in social networks. *ACM Transactions on Knowledge Discovery from Data (TKDD)*, 7(2):1–25, 2013.
- [21] M. McPherson, L. Smith-Lovin, and J. M. Cook. Birds of a feather: Homophily in social networks. *Annual review of sociology*, 27(1):415–444, 2001.
- [22] K. Miller, M. Jordan, and T. Griffiths. Nonparametric latent feature models for link prediction. *Advances in neural information processing systems*, 22:1276–1284, 2009.
- [23] A. Nigam, K. Shin, A. Bahulkar, B. Hooi, D. Hachen, B. K. Szymanski, C. Faloutsos, and N. V. Chawla. One-m: Modeling the co-evolution of opinions and network connections. In *Joint European Conference on Machine Learning and Knowledge Discovery in Databases*, pp. 122–140. Springer, 2018.
- [24] B. Perozzi, R. Al-Rfou, and S. Skiena. Deepwalk: Online learning of social representations. In *Proceedings of the 20th ACM SIGKDD international conference on Knowledge discovery and data mining*, pp. 701–710, 2014.
- [25] J. Tang, M. Qu, M. Wang, M. Zhang, J. Yan, and Q. Mei. Line: Large-scale information network embedding. In *Proceedings of the 24th international conference on world wide web*, pp. 1067–1077, 2015.
- [26] R. Trivedi, M. Farajtabar, P. Biswal, and H. Zha. Dyrep: Learning representations over dynamic graphs. In *International Conference on Learning Representations*, 2019.
- [27] H. Wang, J. Wang, J. Wang, M. Zhao, W. Zhang, F. Zhang, X. Xie, and M. Guo. Graphgan: Graph representation learning with generative adversarial nets. *arXiv preprint arXiv:1711.08267*, 2017.
- [28] X. Wang, P. Cui, J. Wang, J. Pei, W. Zhu, and S. Yang. Community preserving network embedding. In *AAAI*, Vol. 17, pp. 3298239–3298270, 2017.
- [29] L.-k. Zhou, Y. Yang, X. Ren, F. Wu, and Y. Zhuang. Dynamic network embedding by modeling triadic closure process. In *AAAI*, pp. 571–578, 2018.