

ノードの複数役割発見のための転移学習

Transfer learning for discovering multiple roles of node

劉 庶*¹ 鳥海 不二夫*¹

Shu Liu Fujio Toriumi

*¹ 東京大学 The University of Tokyo

要旨: 複雑ネットワークにおいて、ノードの構造的特徴を纏めたものが役割という。実ネットワークでは、1つのノードが複数の役割を有することが観測される。そこで、本研究では単一役割発見フレームワークを拡張し、ノードが持つ複数の役割を発見できるよう転移学習を用いたフレームワークの提案する。提案フレームワークは、構造的特徴量の取得、ソースネットワークの役割知識をターゲットネットワークへの転移、バリデーションネットワークを用いたモデルの選出がポイントである。本手法の精度評価のため、実ネットワークの複数役割の性質から、ネットワークトポロジーから複数役割のノードを有するネットワークの生成モデルを提案する。提案生成モデルで生成したネットワークおよび実ネットワークを用いた実験で、提案フレームワークが従来手法よりもより高い精度で役割を発見できることを示す。

キーワード: 複雑ネットワーク, 役割発見, 転移学習

Abstract: In a complex network, the role is to summarize node location information's structural features. In a real network, it is observed that one node has multiple roles. Therefore, in this study, we extend the single-role discovery framework for nodes using transfer learning to discover multi-roles of nodes. The framework's key points are the acquisition of structural features, transfer of single-role knowledge of the source network to multiple roles of the target network, and selection of a model using the validation network. We also propose a generative model of a network with multi-role nodes from the network topology based on the multi-role nature of the real network. Experiments using the network generated by the proposal generation model and the real network (Wikipedia network) show that the proposed framework achieved higher accuracy than the comparison method.

Keywords: Complex network, Role discovery, Transfer learning

1. はじめに

複雑ネットワークにおける「ノードの役割」とはノードレベルの連結パターンからの構造的特徴を纏めたもので、ノードがネットワーク構造の中でどのような位置に存在するか、またはどのような隣接ノードを持つかを示す。例えば、スターグラフの中心位置に存在する「スター中心」や、中心ノードと接する「スター周辺」、完全グラフに属する「クリークメンバー」等がある[Rossi 15]。ノードの役割発見は物理空間にもサイバー空間でも利用される。例えば、航空網ネットワークにおいて、「スター中心」の役割を有する空港は乗り継ぎに多く利用されることが推定できる。また、オンラインソーシャルネットワークにおいて、「スター中心」の役割を有するユーザはインフルエンサーと見なすことができ、広告配信の効果が大きいと考えられる。

実世界のネットワークでは、構築方法によっては1つのノードが複数の役割を同時に持つことも考えられる。また、時間軸で変化するテンポラルネットワークでは、ノードの役割は時間によって変化することがあり、1つのタイムスライス内で複数の役割が

観測される[Rossi 15]。例えば、人をノードで、人と人の繋がりをリンクで構築した人間関係ネットワークにおいて、平日の勤務時間では会社員で、それ以外の時間では父親の役割を果たすノードは、長いタイムスパンから見ると、会社員と父親の役割を担うノードと言える。また、語彙の共起ネットワークでは、語彙の品詞を役割ラベルとした場合、複数の品詞を持つ語彙が複数の役割を有することになり、テンポラルネットワークのみならず、ノードの複数役割現象は一般に存在すると示す。本質的に、ノードの複数役割現象はネットワークのローカル構造により生じたものと考えられる。前述した人間関係ネットワークは会社のローカル構造と家庭のローカル構造を、語彙共起ネットワークは各ドキュメントによって形成された複数のローカル構造を結合したものを見なせる。異なるローカル構造に異なる役割を担うため、グローバルスケールでは複数役割現象が観測される。

しかしながら、ノードに付与された複数の役割を推定する研究は少ない。ノードに役割を決める際、1つノードに1つ役割ラベルを割り当てるハードアサインメントと違って、各役割の確率を合計1になるよう正規化を行なった上で混合確率ベクトルを予測

結果とするソフトアサインメント方式はこの研究問題のアプローチの1つである[Fu 09] [Xing 10] [Airoldi 08] [Rossi 12]. こういったようなアプローチではテンポラリーネットワークの枠組みには向いているものの、全時間域を纏めたネットワークやテンポラリー性がない静的ネットワークに対する複数役割の推定ができない。

本研究は、転移学習を用いたノードの単一役割発見フレームワーク[Kikuta 20]を、複数役割を高精度で推定できるよう拡張した。また、実ネットワークのローカル構造からグローバル構造を生成することを模倣し、ネットワークポロジリーを元とした複数役割ノードを有するネットワークを生成するモデルを提案する。提案モデルから生成されたネットワークデータを用いた実験で、拡張したフレームワークが従来手法より高精度に役割を発見できることを示す。

2. 関連研究

本研究の関連研究として、役割発見と転移学習を用いた役割発見について述べる。

2.1. 役割発見

役割発見はネットワークの構造に基づき、構造的に類似したノードの抽出を行うタスクである。従来手法において主流となるアプローチは教師なし学習である。

教師なし学習を用いる手法は、ネットワーク表現(隣接行列等)から直接的に役割を発見する Graph-based の手法と、ネットワークから特徴量を抽出し、その特徴量に基づいて役割を発見する Feature-based の手法がある[Rossi 15]. 前者でよく利用される手法の一つに Blockmodel [White 76]がある。ネットワーク表現から構造的に類似するノードをグルーピングしたノード群(ブロックと呼ぶ)、およびそれらのブロック間の関係でコンパクトなグラフを生成する。そのグラフの中にノードを役割に、リンクを役割間の相互作用に見なし、役割を発見する。後者の例として、RoIX [Henderson 12]はノードの特徴量を生成し、作成された特徴量行列に対して、非負値行列因子分解で役割を発見する手法である。

複数役割の発見について、Graph-based の手法として、前述の Blockmodel を変分推論アルゴリズムで拡張した MMSB モデルが提案された[Airoldi 08]. 全ノードに対して各役割に所属する確率ベクトルをディリクレ分布よりサンプリングし、各ノードペア間の発信と受信メンバーシップインジケータ(one-hot ベクトル)を役割所属確率ベクトルからの多項分布より取得し、one-hot ベクトルおよび役割間の交流マトリクスから得たノード間の交流確率に対するベルヌーイ分布からリンクの実在化という一連の過程からネットワークを生成すると仮設する際に、収束後の役割所属確率ベクトルがノードの混合役割になる。また、MMSB モデルを時間域上に拡張した dMMSB モデルも提案された[Fu 09] [Xing 10].

Feature-based の手法については、Role-Dynamics が提案されている。ノード自体の特徴量やエゴネットの特徴量から得られた構造的な特徴量から非負値行列因子分解と最小記述長モデルで構造的役割の特徴量を求め、テンポラリーネットワーク全時間域に適用し、各時刻のネットワークのノードの役割マトリクスを非負値行列因子分解で計算する。[Rossi 12]

ここに注意すべき点は、MMSB と dMMSB の場合、ある時刻の役割所属確率ベクトルは合計値が 1 になるように正規化したものになり、具体的にどの役割に所属するかは明らかにならない。また、Role-Dynamics も複数役割に所属することに対応していない。

2.2. 転移学習を用いた役割発見

転移学習はリンク予測[Cao 10]等によく使われる手法であるが、役割発見ではあまり用いられない。[Kikuta 20]の提案手法では、予めノードの役割ラベリング済みネットワーク(ソースネットワークと呼ぶ)を用いて予測したいネットワーク(ターゲットネットワークと呼ぶ)内のノードの複数役割を推定する。ソースネットワークは必ずしも複数役割を持つノードを有する必要がない。また、一度作成できれば、複数のターゲットネットワークに応用できるため、ラベリングコストの削減を期待できる。実際に応用する場合、両方のネットワークは大きさが異なったりすることで、ノードの分散表現はそれぞれのサブスペースを形成しやすく、役割の予測が困難になるため、ドメイン 敵対的学習[Kikuta 19]を用いて、両ネットワークのノードの分散表現に基づいて、ノードの役割を推定する。[Kikuta 20]の提案手法は精度の高い転移学習を実現したが、複数の役割を持つ場合は推定できない。そのため、本研究では、[Kikuta 20]の手法を複数の役割を推定できるよう拡張した。

3. 提案手法

本研究では転移学習を用いたノードの複数役割発見手法を提案する。本手法には、以下の2つから成る。

- 構造的表現の取得: ノードの分散表現を取得
- 転移学習による複数役割の予測: 転移学習でソースネットワークの役割知識から、ターゲットネットワークのノードの複数役割を推定

3.1. 構造的表現の取得

本研究ではノードの分散表現を `struc2vec` で取得する。`struc2vec`はノードの構造的類似度を基に潜在表現を学習するフレームワークであり、階層構造を用いて異なるスケールでノードの類似性を測定し、多層グラフを構築して構造の類似性をエンコードし、ノードの構造コンテキストを生成する。そのため、生成された分散表現は、ノードやリンクの属性に依存せず、「位置」から独立するとともに、類似なローカルネットワーク構造を持つ2つのノードは表現空間上に近くに配置することになる。

`struc2vec` では以下4つの手順でノードの分散表現を計算する。

(1) 異なる近隣サイズのネットワーク内の各頂点ペア間の構造的類似性を以下の式で計算する。

$$f_k(u, v) = f_{k-1}(u, v) + g\left(s(R_k(u)), s(R_k(v))\right)$$

$$k \geq 0 \text{ 且 } |R_k(u)|, |R_k(v)| > 0$$

$f_k(u, v)$ は k ホップ先までのローカルネットワーク内のノード u と v の類似度を示し、 $f_{-1} = 0$ になる。 $R_k(u)$ はノード u からの k ホップ先のノード群、 $s(R_k(u))$ は $R_k(u)$ の次数集合を昇順でソートしたリストである。 g は二つのリストの距離を測定する関数であり、ここでは動的時間伸縮法 [Rakthanmanon 13]を用いる。

(2) 重み付き多層グラフを構築する。ネットワーク内のすべてのノードがすべてのレイヤに存在するものとする。各レイヤ内のすべてのノードペア間のエッジの重みは、構造の類似性に反比例するように以下のように定義する。

$$w_k(u, v) = e^{-f_k(u, v)}, k = 0, \dots, k^*$$

ここで、 $w_k(u, v)$ は k レイヤ目におけるノード u と v 間のリンクの重みを示す。また、同一ノードの上下レイヤ間のリンクの重みは以下に定義する。

$$w(u_k, u_{k+1}) = \log(\Gamma_k(u) + e), k = 0, \dots, k^* - 1$$

$$w(u_k, u_{k-1}) = 1, k = 1, \dots, k^*$$

$$\Gamma_k(u) = \sum_{v \in V} \mathbf{1}(w_k(u, v) > \bar{w}_k)$$

$\Gamma_k(u)$ は k レイヤ目におけるノード u からのリンクの内、完全グラフのリンクの平均重みよりも大きいリンクの数を示す。ノード u

があるレイヤにおいて類似ノードが多ければ多い場合、ほかのレイヤに移る確率が高くなる。 k が大きくなると、類似するノードの数が減ることもわかる。

(3) 多層グラフを使用して、各ノードのコンテキストを生成する。このとき、多層グラフのバイアス付きランダムウォークを使用して、ノードシーケンスを生成する。

あるノードのシーケンスを生成する時のランダムウォークを考える。まず、ランダムウォークする対象は確率 q で同一レイヤに留まる。その時、ノード u から v に遷移する確率は以下の式で定義する。

$$p_k(u, v) = e^{-f_k(u, v)} / Z_k(u)$$

$$Z_k(u) = \sum_{v \in V, v \neq u} e^{-f_k(u, v)}$$

$Z_k(u)$ は k レイヤにおけるノード u の正規化項である。

そして $1 - q$ の確率で上下のレイヤに遷移する。具体的な確率は以下の式で求める。

$$p_k(u_k, u_{k+1}) = w(u_k, u_{k+1}) / (w(u_k, u_{k+1}) + w(u_k, u_{k-1}))$$

$$p_k(u_k, u_{k-1}) = 1 - p_k(u_k, u_{k+1})$$

$k + 1$ レイヤ目で生成されたコンテキストは k レイヤ目のコンテキストのサブコンテキストであるため、階層的コンテキストが得られる。ランダムウォークは比較的小さいステップ数に固定し、複数回独立に試すことで、各ノードの構造的に類似するノード間のコンテキストを生成することができる。

(4) ノードのシーケンスで指定されたコンテキストから潜在表現を学習する手法を適用する。ここで、Skip-Gram [Mikolov 13]を使用する。

3.2. 転移学習による複数役割の予測

本研究ではラベリングコストや予測結果評価の妥当性等が優れるフレームワーク[Kikuta 20]を複数役割が推定できるように拡張した。

[Kikuta 20]の手法は、図1に示すように、DiscriminatorとRole-modelの2つのニューラルネットワークから構成される。Discriminatorはソースネットワークとターゲットネットワークのノードの分散表現(図1のNode representations)を入力とし、その分散表現はどちらのネットワークに所属したノードの分散表現なのかを識別できるように学習する。Role-modelはソースネットワークのノードの分散表現を入力とし、対応するノードの役割を予測するとともに、両ネットワークのノードの分散表現を似せることで、Discriminatorが識別できないように学習する。敵対的学習のフレームワークに則り、2つのニューラルネットワークを交互に学習することで、ソースネットワークとターゲットネットワークのノードの分散表現の分布の差を緩和し、それぞれ形成されたサブスペースをなくし、より精度の高い転移学習を実現した。

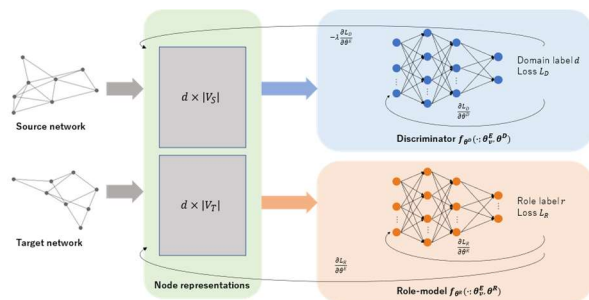


図 1 役割発見におけるドメイン敵対的学習のパイプライン

複数役割を推定できるよう、[Kikuta 20]のRole-modelのニューラルネットワークの出力層の活性化関数を softmax から sigmoid に、損失関数をクロスエントロピー損失からバイナリクロスエントロピーに変更した。また、評価基準を Macro-F1 値からの部分正解率と完全正解率に変更した。

具体的に、Role-model は3層のニューラルネットワークにする。入力層と中間層は ReLU の活性化関数を持つ全結合層で、dropout[Srivastava 14]を適用する。出力層は sigmoid の活性化関数を持つ全結合層である。Role-model のパラメータを θ^R 、入力であるソースドメインのノードの分散表現を θ^S 、出力役割マトリクスを $\hat{y}^S = f_{\theta^R}(\theta^S)$ とする。損失関数 $L_R(S; \theta^R, \theta^E)$ は以下の式で計算する。

$$L_R(S; \theta^R, \theta^E) = -\frac{1}{|S| \times |N|} \sum_{v \in S} \sum_{n \in N} y_n^v \log \hat{y}_n^v + (1 - y_n^v) \log(1 - \hat{y}_n^v)$$

$|S|$ と $|N|$ はそれぞれソースネットワークのノード数と役割数であり、 y_n^v と \hat{y}_n^v はノード v の n 番目役割の正解ラベルと予測ラベルである。

部分正解率は、全ノードの全役割ラベルの中、正しく予測できたラベルの割合である。

$$Acc_{percent} = \frac{\sum_v \sum_{n \in N} \sigma(\hat{y}_n^v, y_n^v)}{|V| \times |N|}$$

$\sigma(x, y)$ は $x = y$ の場合が1に、そうでない時が0になる関数である。 $|V|$ はノードの総数である。

完全正解率は全ノードの中、全ての役割ラベルが全部正しく予測できたノードの割合である。

$$Acc_{perfect} = \frac{\sum_v \sigma(\hat{y}^v, y^v)}{|V|}$$

\hat{y}^v, y^v はそれぞれノード v の役割予測ベクトルと正解ベクトルである。

4. 提案手法の評価

本章では、複数役割向けのネットワーク生成モデルで生成したネットワークと wikipedia¹[Zhang 19]の実ネットワークを用いた実験、およびその結果を述べる。

4.1. 生成モデルで生成したネットワークの実験

4.1.1. 複数役割向けのネットワーク生成モデル

本研究に用いるネットワークを生成するモデルを紹介する。

ノードが異なるローカル構造に異なる役割を担うことから、それぞれのローカル構造を層と捉え、全体のネットワークは複数の層を結合したものと解釈できる。そのため、ネットワークの単位構造から複数の層を生成し結合する形で生成モデルを考える。また、ネットワーク構造で最も基本的なネットワークポロジとして、スター、メッシュ、リング、ツリー、パス、パスがある。複雑ネットワーク科学で扱われているノードとリンク以外の伝送媒体を含んでいるパスを除き、本研究ではスター、メッシュ、リング、ツリー、パス、5つのネットワークポロジを実験対象にする。また、表1に示すように、ネットワークポロジの各ノードはそれぞれ1つの役割だけを有するため、トポロジーの結合により1つのノードに複数の役割を持たせる。ネットワークポロジ間に単純にリンクを張る方式では1ノードに3つ以上の役割を割り当てるのが難しいため、複数役割を持つノードの割合や1ノードを持つ最大役割数をコントロールできる多層ネットワークによるネットワーク生成モデルを提案する。

¹ <http://www.matmahoney.net/dc/text.html>

ネットワーク生成モデルでは以下4つのハイパーパラメータを持つ。

- n…ネットワークトポロジーの総数
- m…多層ネットワークの層数(1ノードを持つ最大役割数)
- p…複数役割を持つノードの確率(割合)
- q…層間結合関係の形成確率

生成過程は以下5ステップになる。

1. n 個のネットワークトポロジーをランダムに生成
2. 各ネットワークトポロジーを確率 $p_i = (-N_i + \sum_{k=1}^m N_k) / ((m-1) \sum_{k=1}^m N_k)$ で i 層目に割り当てる。 N_i は既に i 層目に割り当て済みノードの数である。
3. 各層において、確率 p でノードを選択し、結合ノード候補の集合を生成
4. 各層の結合ノード候補の集合から1ノードずつ取り出し、確率 q で層間結合する。層間結合ノードに結合前のノードの役割と「結合」役割を割り当てる。
5. 結合ノードを基に各層を1層に結合。

こうした生成過程で、複数役割を持つノードの割合を p で、1ノードを持つ最大役割数を m で直接的にコントロールできる。また、n が生成したネットワークのスケールを、q がノードの役割数のバリエーションを間接的に制御できる。

表1 ネットワークトポロジーとノードの役割

No.	役割名	トポロジー	対象ノード
1	スター中心	スター	スター構造に中心を位置するノード
2	スター周辺	スター	スター構造に中心以外のノード
3	メッシュ	メッシュ	メッシュ構造のノード
4	リング	リング	リング構造のノード
5	木の根	ツリー	ツリー構造の根ノード
6	木の枝	ツリー	ツリー構造の親ノードと子ノードを共に持つノード
7	木の葉	ツリー	ツリー構造の子ノードを持たないノード
8	パス中間	パス	パス構造の両端以外のノード
9	パス端点	パス	パス構造の両端のノード

4.1.2. データセット

ソースネットワークとして各種のネットワークトポロジーを一つずつ組み合わせ合わせたネットワークを用いる。ターゲットネットワークと検証ネットワークは前述した生成モデルで生成したものにする。各ネットワークを生成するハイパーパラメータ、および、ネットワークの基礎統計量は表に示す。m が2から10までに変化し、他のハイパーパラメータが固定した状態で生成したネットワークを用いて計9セットの実験を実施した。

4.1.3. 比較手法

比較手法としては、struc2vec で得られたソースネットワークのノードの分散表現を入力とし、3層ニューラルネットワークモデルに役割ラベルを予測できるように学習した後に、ターゲットネットワークのノードの役割ラベルを学習済みモデルで予測する。

4.1.4. 結果

評価指標として、部分正解率と完全正解率を用いる。それぞれの評価指標で、ハイパーパラメータに対するグリッドサーチを実施し、検証ネットワークの予測精度が最大のモデルでのターゲットネットワークの予測結果を採用する。

提案手法と比較手法で、各セットに対して異なるランダムシードで6回実行した結果を図2と図3に示す。横軸の P と C はそれぞれ提案手法と比較手法を、数字はネットワーク生成時の層数(m)を表す。縦軸は予測精度である。箱ひげ図において、白抜きは異常値、つまり、箱の上(下)限よりも大きい(小さい)値を、緑の三角が6回実験の平均値(異常値を含む)を示す。




図 2 生成モデルで生成したネットワークの実験結果 (部分正解率)

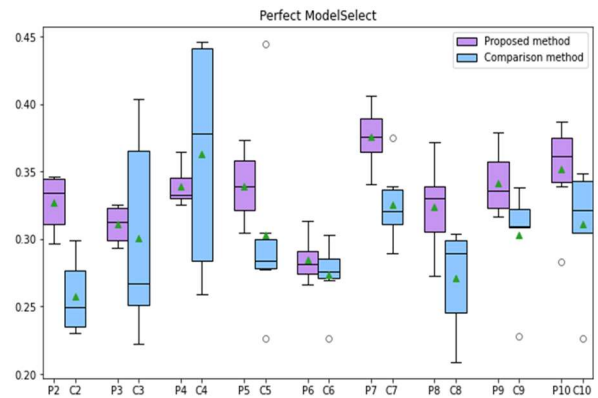


図 3 生成モデルで生成したネットワークの実験結果 (完全正解率)

部分正解率では提案手法は比較手法と同レベルの精度(0.80~0.85)であったが、平均完全正解率では提案手法がm=4の実験を除き、全般に上回った精度を発揮していた。これは提案手法が各役割の構造的特徴をソースネットワークからより正確に学習できたことを示す。ソースネットワークがネットワークトポロジーを結合しないままに使用していたので、単一役割のみのソースネットワークから複数役割のターゲットネットワークに役割知識を転移できたことを示す。これは提案手法が複数役割のノードをもつソースネットワークを用意しなくても応用できることが判る。

そして、完全正解率の場合、提案手法が6回実験の結果の分散が比較手法より小さいことと、異常値の数も少ないことが判る。これは提案手法が安定した学習結果を得たためであると考えられる。

また、ターゲットネットワークと検証ネットワークを生成する時の層数(m)が2から10にかけて、ノードが持つ役割数も2から

10に増加したが、予測結果には傾向性が現れていなかった。これは提案手法がノードの役割数が多い場合でも一定の予測精度水準を保証できることを示す。

m=4 の実験において、比較手法より低い精度になっていたことはネットワーク生成時のランダム性や学習時のランダム性(特に比較手法の不安定性)によるものと推測する。

4.2. wikipedia の実ネットワークの実験

4.2.1. データセット

Wikipedia の実ネットワーク[Zhang 19]は Wikipedia の一部分をコーパスとした単語の共起ネットワークであり、4,777 個のノードと 184,812 個のリンク、および、40 種のノード役割ラベル(単語の品詞ラベル)を有する。全体のネットワーク(Wiki-all)に対して Leiden 法[Traag 19]でコミュニティ抽出を行い、その結果から3つのサブネットワーク(Wiki-c1, Wiki-c2, Wiki-c3)を無作為に選出し、それぞれソースネットワーク、ターゲットネットワークとバリデーションネットワークにした。また、3サブネットワークにおいて、共通する役割ラベル 18 個を予測対象とした。各ネットワークの基本統計量は表2に示す。

表2 Wikipedia ネットワークの基本統計量

データセット	ノード数	リンク数	ラベル数
Wiki-all	4,777	184,812	40
Wiki-c1	958	7,946	18
Wiki-c2	1,633	8,550	18
Wiki-c3	442	1,982	18

4.2.2. 結果

提案手法と比較手法で、それぞれ6つのランダムシードで実行した結果が表3, 図4と図5に示す。図4と図5の見方は 4.1.4 の図2と図3と同じである。

表3 Wikipedia ネットワーク実験結果

評価指標	提案手法	比較手法
部分正解率(平均)	0.924	0.923
完全正解率(平均)	0.386	0.108

部分正解率では提案手法は比較手法と同レベルの精度(0.92前後)であったが、完全正解率では比較手法より遥かに高い精度を達成していた。これはソースネットワークにおいて役割が1ノードに複数役割に対応する場合でも、提案手法で各役割の構造的特徴、および、役割の組み合わせパターンを学習できたことを示す。また、図5から提案手法が安定した学習結果を得たことが判る。

そして、実ネットワークのデータを扱う際に、ソースネットワークとバリデーションネットワークをコミュニティ抽出で得られたサブネットワークを使用することができることが判る。比較的小さいソースネットワークとバリデーションネットワークから大きいターゲットネットワークの役割発見ができたため、提案手法の転移学習でスケールの差を緩和したからだと考察する。また、サブネットワーク間には構造的バイアスや役割的バイアスがあるにも関わらず、高い精度で役割発見できたことは提案手法の敵対的学習が効果を発揮したためであると考えられる。

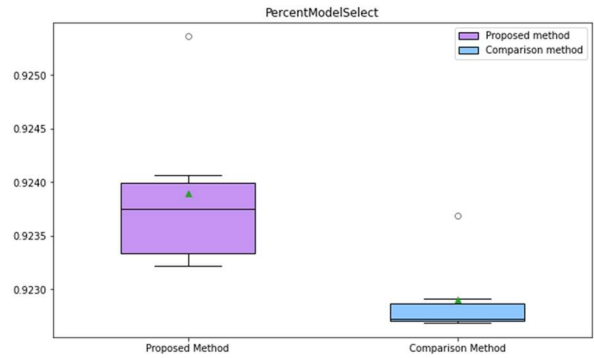


図4 Wikipedia ネットワークの実験結果 (部分正解率)

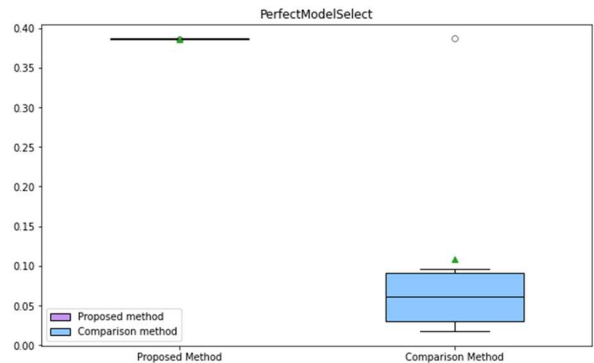


図5 Wikipedia ネットワークの実験結果 (完全正解率)

5. おわりに

本研究では、転移学習を用いたノードの単一役割発見手法を拡張し、複数役割発見に適用可能であることを示した。また、実ネットワークの複数役割の性質を模倣し、ネットワークポロジからネットワークを生成するモデルを提案し、生成されたネットワークを用いて、単一役割のみのソースネットワークからターゲットネットワークの複数役割を予測できたことを示した。さらに、実ネットワークをコミュニティ検出で複数のサブネットワークに分割し、比較的小さいソースネットワークとバリデーションネットワークをラベリングし、大きいターゲットネットワークの複数役割予測に成功できたことで、実ネットワークの役割発見問題の扱い方に1つの方向性を示した。

実ネットワークを扱う際に、コミュニティ発見で得られたサブネットワークが構造的バイアスと役割的バイアスが大きくて、学習やモデル選択に適用できない場合がある。そのため、より成功率が高い実ネットワークの扱い方を探索することが今後の課題になる。

文 献

- [Kikuta 20] Kikuta, S., Toriumi, F., Nishiguchi, M., Liu, S., Fukuma, T., Nishida, T., & Usui, S. (2020). Framework for role discovery using transfer learning. *Applied Network Science*, 5(1), 1-19.
- [Kikuta 19] Shumpei Kikuta, Fujio Toriumi, Mao Nishiguchi, Tomoki Fukuma, Takanori Nishida, Shohei Usui : Domain-Invariant Latent Representation Discovers Roles, *COMPLEX NETWORKS 2019: Complex Networks and Their Applications VIII* pp 834-844, 2019

- [Rossi 15] Ryan A. Rossi and Nesreen K. Ahmed: Role Discovery in Networks, *IEEE Transactions on Knowledge & Data Engineering (TKDE)*, vol. 27, no. 4, pp. 1112-1131, 2015
- [Ahmed 17] Nesreen K. Ahmed, Ryan A. Rossi, Theodore L. Willke, and Rong Zhou: Edge Role Discovery via Higher-Order Structures, *PAKDD 2017: Advances in Knowledge Discovery and Data Mining* pp 291-303, 2017
- [Ribeiro 17] Leonardo F. R. Ribeiro, Pedro H. P. Savarese, Daniel R. Figueiredo: struc2vec: Learning Node Representations from Structural Identity, arXiv:1704.03165v3 [cs.SI] 3 Jul 2017, 2017
- [White 76] Harrison C. White, Scott A. Boorman and Ronald L. Breiger: Social Structure from Multiple Networks. I. Blockmodels of Roles and Positions, *American Journal of Sociology* Vol. 81, No. 4 (Jan. 1976), pp. 730-780, 1976
- [Henderson 12] Keith Henderson, Brian Gallagher, Tina Eliassi-Rad, Hanghang Tong, Sugato Basu, Leman Akoglu, Danai Koutra, Christos Faloutsos, Lei Li: RolX: Structural Role Extraction & Mining in Large Graphs, *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 1231-1239, 2012
- [Rakthanmanon 13] Rakthanmanon T, Campana B, Mueen A, Batista G, Westover B, Zhu Q, Zakaria J, Keogh E: Addressing Big Data Time Series: Mining Trillions of Time Series Subsequences Under Dynamic Time Warping, *ACM Transactions on Knowledge Discovery from Data*, 2013
- [Cao 10] Bin Cao, Nathan Nan Liu, Qiang Yang: Transfer Learning for Collective Link Prediction in Multiple Heterogenous Domains, *Proceedings of the 27th International Conference on Machine Learning (ICML-10)*, 2010
- [Mikolov 13] Tomas Mikolov, Ilya Sutskever, Kai Chen, Greg S Corrado, and Jeff Dean: Distributed representations of words and phrases and their compositionality, *Advances in neural information processing systems*, pages 3111–3119, 2013
- [Hartigan 79] Hartigan, J. A. and Wong, M. A.: Algorithm AS 136: A k-means clustering algorithm, *Journal of the Royal Statistical Society. Series C (Applied Statistics)*, Vol. 28, No. 1, pp. 100–108, 1979
- [Fu 09] W. Fu, L. Song, and E. Xing, “Dynamic mixed membership blockmodel for evolving networks,” in *ICML*, 2009, pp. 329–336.
- [Xing 10] E. Xing, W. Fu, and L. Song, “A state-space mixed membership blockmodel for dynamic network tomography,” *Ann. Appl. Stat.*, vol. 4, no. 2, pp. 535–566, 2010.
- [Airoldi 08] E. M. Airoldi, D. M. Blei, S. E. Fienberg, and E. P. Xing, “Mixed membership stochastic blockmodels,” *JMLR*, vol. 9, pp. 1981–2014, 2008.
- [Rossi 12] R. Rossi, B. Gallagher, J. Neville, and K. Henderson, “Roledynamics: Fast mining of large dynamic networks,” in *WWW LSNA*, 2012, pp. 997–1006.
- [Zhang 19] Zhang, Jie and Dong, Yuxiao and Wang, Yan and Tang, Jie and Ding, Ming, “ProNE: Fast and Scalable Network Representation Learning”, *IJCAI-19*, pp.4278-4284, 2019
- [Traag 19] Traag, V. A., Waltman, L., & van Eck, N. J. (2019). From Louvain to Leiden: guaranteeing well-connected communities. *Scientific reports*, 9(1), 1-12.
- [Srivastava 14] Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, 15(1), 1929-1958.