


When Does Label Propagation Fail? A View from a Network Generative Model

[IJCAI'17]

Yuto Yamaguchi and Kohei Hayashi




ネットワーク生成モデルの 見地から LP の性質を解析する





問題定義 | ラベル分類


Given 部分的にラベルが付いた
無向グラフ



Find 全部のラベル



例 | SNSユーザの属性推定






- 真ん中の人の趣味は何？

Label Propagation (1/2)

[Zhu+, 03], [Zhou+, 03], など

既知のラベルを伝播させる



Label Propagation (2/2)

[Zhu+, 03], [Zhou+, 03], など

隣接行列 X と既知のラベル Y が与えられたとき
 Q を最大にする $F = \{f_i\}$ を求める


$$Q(F; X, Y, \lambda) = \frac{1}{2} \sum_{i=1}^N \|f_i - y_i\|_2^2 + \frac{\lambda}{2} \sum_{i=1}^N \sum_{j=1}^N x_{ij} \|f_i - f_j\|_2^2$$

既知のラベルと推定ラベルは
出来るだけ等しい


隣り合うノードのラベルは
出来るだけ等しい

LP がうまくいかないケース

同一のラベルが隣り合わないケース



ラベルの割合が偏っているケース




Q. なんでうまくいかない？

Q. 他にはどういうケースがある？

本研究の成果

- LP と SBM の理論的なつながりを示す
- ネットワーク生成モデルの見地からLPの性質を解析
- LPが(暗黙的に)置いている仮定を示す


Network Generative Model



入力されたパラメータとモデルの仮定をもとに
実際のネットワーク(データ)を生成する

Stochastic Block Model (1/2)

パラメータ



SBM の仮定

- 全てのノードは K 個あるクラスタのうち**必ずどれか一つ**に属す
 - 属す確率は K 次元確率ベクトル γ によって定まる
- あるノード i と j の間にエッジが存在する確率は i と j が**属すクラスタのみ**によって定まる
 - 接続確率は $K \times K$ 行列 Π によって定まる

Stochastic Block Model (2/2)

生成過程

多項分布

①

● For each node $i = 1, \dots, N$

– Generate $z_i \sim \underline{Mult}(\cdot | \underline{\gamma})$

パラメータ

②

● For each node pair (i, j)

– Generate $x_{ij} \sim \underline{Bern}(\cdot | z_i^T \underline{\Pi} z_j)$


パラメータ

ベルヌーイ分布

①: 各ノードのクラスタ割り当て z を生成


②: 隣接行列 x の要素を生成

LP と SBM の理論的關係



Partially Labeled SBM (PLSBM)

パラメータ



PLSBM の仮定

- SBM の仮定
- 一部のノードはクラスタ割り当てとは別に **“ラベル”** を持つ
 - ラベルとクラスタ割り当ては α が大きいほど一致する

Partially Labeled SBM (PLSBM)

生成過程

①

- For each node $i = 1, \dots, N$
 - Generate $z_i \sim \text{Mult}(\cdot | \gamma)$

②

- For each labeled node $i = 1, \dots, N_L$
 - Generate $y_i \sim \text{Mult}(\cdot | \underline{B} z_i)$

③

- For each node pair (i, j)
 - Generate $x_{ij} \sim \text{Bern}(\cdot | z_i^T \mathbf{\Pi} z_j)$


SBMに
②を追加

パラメータ α
によって計算される


- ②: 各ノードの“ラベル”を生成
(クラスタ割り当てをもとに生成される)

PLSBM でラベル推定

隣接行列 X と(一部の)ラベル y が与えられた上で z を推定



LP と SBM の理論的關係



Discrete Label Propagation

隣接行列 X と(一部の)ラベル y が与えられた上で z を推定


DLPの目的関数 (LPと同じ)

$$Q(Z; X, Y, \lambda) = \frac{1}{2} \sum_{i=1}^N \|z_i - y_i\|_2^2 + \frac{\lambda}{2} \sum_{i=1}^N \sum_{j=1}^N x_{ij} \|z_i - z_j\|_2^2$$

Q を最大化する z を求める (組み合わせ最適化)

→ Label propagation は z を連続緩和して解いている

LP と SBM の理論的關係



主結果：PLSBM と DLP の関係

以下の条件が満たされるとき、
DLP の解と LSBM における z の MAP 推定は一致

- Condition 1: $\gamma_k = 1/K$ for all k ,
- Condition 2: $\Pi = \mu I + \nu(\mathbf{1}\mathbf{1}^T - I)$,
- Condition 3: $\lambda \ln \frac{\alpha(K-1)}{1-\alpha} = \ln \frac{\mu(1-\nu)}{\nu(1-\mu)}$
- Condition 4: (略)

Condition 1

$$\gamma_k = 1/K \text{ for all } k,$$

言っていること

- γ の値は全ての k において等しい

Implication (DLPの暗黙的仮定)

- ネットワーク上のラベルの割合は一定

Condition 2

$$\mathbf{\Pi} = \mu \mathbf{I} + \nu (\mathbf{1}\mathbf{1}^T - \mathbf{I})$$

言っていること

- $\mathbf{\Pi}$ の対角成分の値はそれぞれ等しい
- $\mathbf{\Pi}$ の非対角成分の値はそれぞれ等しい

Implication (DLPの暗黙的仮定)

- 各クラスタ内のエッジの密度はそれぞれ等しい
- 各クラスタ間のエッジの密度はそれぞれ等しい

Condition 3

$$\lambda \ln \frac{\alpha(K-1)}{1-\alpha} = \ln \frac{\mu(1-\nu)}{\nu(1-\mu)}$$

言っていること

- $\lambda > 0$ かつ $\alpha > 1/K \Rightarrow \mu > \nu$

Implication (DLPの暗黙的仮定)

- (LPは必ず λ が正なので)
既知のラベルがランダム以上に合っていれば
クラスタ内のエッジ密度はクラスタ間よりも大きい

まとめ

- Label Propagation と Stochastic Block Model の理論的なつながりを示した
 - Label Propagation をネットワーク生成モデルとして解釈
- Label Propagation が暗黙的に置いている仮定を示した