

ニューラルネットワークを用いたグラフ埋め込みによる表現学習



奥野 彰文^{1,2}

Kim Geewook^{1,2}

下平 英寿^{1,2}




¹ 京都大学大学院 情報学研究科 システム科学専攻 ² 理化学研究所 革新知能統合研究センター (AIP)


1. グラフ埋め込みとは？

グラフ埋め込みは、グラフ状の関係性を持ったデータ（ノード）を扱いやすい形式（ベクトル）に変換する方法です。あらかじめデータのベクトル表現が得られている場合、データの次元削減（データ圧縮）ができます。変換にはニューラルネットワークが使えます。


例1: 友達ネットワークの埋め込み



例2: 英単語 概念辞書の埋め込み (単語埋め込み)



例3: 論文共著ネットワークの埋め込み




定式化

入力 | 各ノード v_i のベクトル表現 $x_i \in \mathbb{R}^p$ (未観測なら 1-hot)
重み付き隣接行列 $W = (w_{ij})$

$$\ell(\theta) := \sum_{1 \leq i < j \leq n} (w_{ij} - \exp(\langle f_{\theta}(x_i), f_{\theta}(x_j) \rangle))^2$$

などを最小化 (f_{θ} : ニューラルネットワーク)

出力 | 各ノード v_i のベクトル表現 $y_i = f_{\theta}(x_i) \in \mathbb{R}^K$
(普通は $K \leq p$)



やっていることのまとめ: v_i と v_j の関係の強さを内積 $\langle f_{\theta}(v_i), f_{\theta}(v_j) \rangle$ の関数で当てるように埋め込み $f_{\theta}(v_i) \in \mathbb{R}^K$ を計算

2. 我々の貢献

Research Question: $\langle f_{\theta}(v_i), f_{\theta}(v_j) \rangle$ 以外の類似度を使うとどうなる？

Answer: 埋め込みの次元が高ければ内積を他の正定値類似度に変えても同じ(貢献1)だが、提案した類似度を使えば、より広いクラスの関数を表現できる(貢献2)。

貢献1) ベクトル値ニューラルネットワークの内積 (Inner Product Similarity; IPS) $\langle f_{\theta}(x_i), f_{\theta}(x_j) \rangle$ が表現できる関数の広さを調べた。
(Okuno et al., ICML2018 定理 5.1)

主結果: IPS $\langle f_{\theta}(v_i), f_{\theta}(v_j) \rangle$ は任意の正定値類似度 $g(v_i, v_j)$ を近似できるが、それ以上は近似できない。

貢献2) 新たな類似度 Shifted IPS (SIPS) $\langle f_{\theta}(x_i), f_{\theta}(x_j) \rangle + u_{\psi}(x_i) + u_{\psi}(x_j)$ を提案し、IPSより高い表現能力を持つことを示した。
(Okuno and Shimodaira, ICML2018-TADGM WS; Okuno et al., AISTATS2019, to appear)


主結果: 提案したSIPSは任意の条件付き正定値類似度を近似できる! (⇔ SIPSはIPSや他の既存法を含む一般化)



最近、双曲空間でのグラフ埋め込みが注目を集めている:

ポアンカレ埋め込み (Nickel and Kiela, NIPS2017) はポアンカレ距離を用いて木(グラフ)を円板上に埋め込む。

既存手法
Nickel and Kiela (2017) 図2(b)より



提案法: Okuno et al. (2019) 図1より

実データでの実験

C-authorship net (Prado et al., 2013) と WordNet (Miller, 1995) の特徴ベクトルを学習し、それぞれでリンク予測、概念辞書の再構成を行い ROC-AUCスコアを計算した。値は大きいほうが良い。類似度に負の二乗距離 (NSD), ポアンカレ距離, IPS, SIPS (提案) を用いた。Kは埋め込みの次元。

	Co-authorship network				WordNet			
	K=2	K=5	K=10	K=20	K=2	K=5	K=10	K=20
NSD	0.822±0.010	0.866±0.014	0.877±0.012	0.865±0.033	0.792±0.007	0.900±0.001	0.957±0.001	0.984±0.000
Poincare	0.707±0.021	0.874±0.001	0.882±0.001	0.884±0.001	0.840±0.007	0.979±0.001	0.987±0.000	0.985±0.000
IPS	0.780±0.005	0.883±0.001	0.896±0.001	0.896±0.001	0.725±0.006	0.760±0.006	0.769±0.002	0.792±0.002
SIPS (提案)	0.781±0.001	0.885±0.001	0.896±0.002	0.897±0.001	0.963±0.001	0.977±0.001	0.983±0.001	0.987±0.000

理論

Okuno et al. (AISTATS2019) 定理5.2

g を条件付き正定値カーネル, $f_x \in \mathbb{R}^K$ をベクトル値連続関数, $S(W_f, K)$ を層の数 $O(W_f)$ で幅が $O(1)$ のディープニューラルネットワークの集合とすると

$$\inf_{u \in S(W_u, 1)} \sup_{x, x' \in X} |g(f_x(x), f_{x'}(x')) - (\langle f(x), f(x') \rangle + u(x) + u(x'))| = O\left(K^{-\frac{1}{K}} + K^{\frac{1}{2} + \frac{2}{p}} W_f^{-\frac{2}{p}} + W_u^{-\frac{2}{p}}\right).$$

参考文献

- Nickel, Maximilian, and Douwe Kiela. "Poincaré Embeddings for Learning Hierarchical Representations." *Advances in Neural Information Processing Systems (NeurIPS)*. 2017.
- Okuno, Akifumi, Tetsuya Hada, and Hidetoshi Shimodaira. "A probabilistic framework for multi-view feature learning with many-to-many associations via neural networks." *Proceedings of the 35th International Conference on Machine Learning (ICML)*. Stockholm, Sweden, 2018. PMLR 80:3888-3897.
- Okuno, Akifumi, and Hidetoshi Shimodaira. "On Representation Power of Neural Network-Based Graph Embedding and Beyond." *ICML 2018 workshop on Theoretical Foundations and Applications of Deep Generative Models, CoRR abs/1805.12332*, 2018
- Okuno, Akifumi, Geewook Kim, and Hidetoshi Shimodaira. "Graph Embedding with Shifted Inner Product Similarity and Its Improved Approximation Capability." *CoRR abs/1810.03463*, (to appear in AISTATS2019)



Contact info: A. Okuno
http://okuno.org