

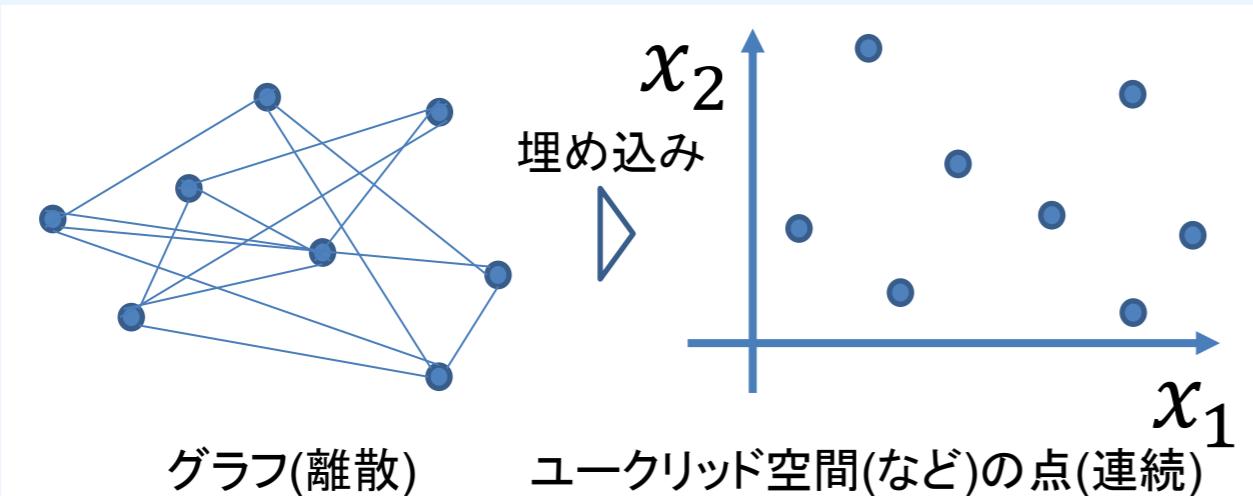
2-21: Dimensionality and Curvature Selection of Graph Embedding using Decomposed Normalized Maximum Likelihood Code-Length

(DNML符号長を用いたグラフ埋め込みの次元・曲率選択; ICDM2023)

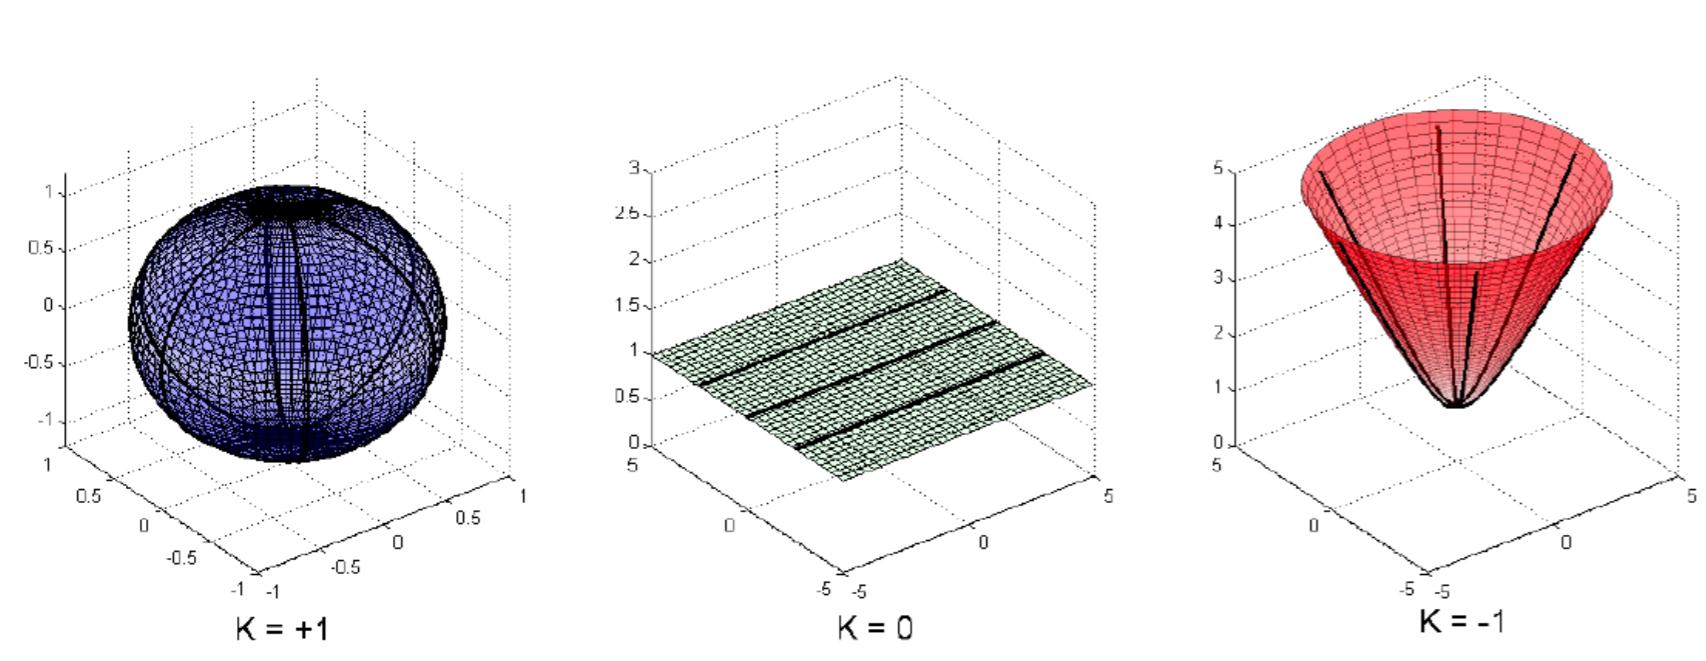
結城 凌 (東京大学); 鈴木 悅 (King's College London); 山西 健司 (東京大学)

研究目的

- グラフ埋め込み研究の発展 [1, 2].



- 次元・空間の選択研究 [3, 4, 5].
 - リンク予測・ノード分類の性能に影響.
- ユークリッド空間・双曲空間・球面.
 - 単連結定曲率リーマン多様体.
 - 埋め込み先空間としてスタンダード.
 - 空間選択→曲率の選択.



本研究の貢献: 次元および曲率の同時選択手法の考案.

提案手法

- 潜在変数モデルを設定 [5].
 - Wrapped Normal Distribution[6, 7]を用いる.
 - ガウス分布の多様体への拡張.
- Minimum Description Length (MDL) 原理 [8]を用いる.
 - 統計的モデル選択基準の1つ. 与えられたデータを最も短く符号化するモデルを最良とする.
 - 一致性 [9, 10]・PAC学習での早い収束 [11]など.
- Decomposed Normalized Maximum Likelihood (DNML) 符号長 [12].
 - 潜在変数モデルで簡単に符号長を計算可能な手法.

$$L_{\text{DNML}}(y, z) := L_{\text{NML}}(y|z) + L_{\text{NML}}(z),$$

$$L_{\text{NML}}(y|z) := -\log p(y|z; \hat{\beta}(y, z)) + \log \sum_{\bar{y}} p(\bar{y}|z; \hat{\beta}(\bar{y}, z)),$$

$$L_{\text{NML}}(z) := -\log p(z; \hat{\sigma}(z)) + \log \int p(\bar{z}; \hat{\sigma}(\bar{z})) d\bar{z}_{1:D},$$

DNMLを最小化する次元 D ・曲率 K 選択.

実験および結果

- 1. 人工データでの次元・曲率同定実験.

Table 4.1: Accuracy of curvature sign estimation.

Dataset	# of nodes	DNML	AIC	BIC
E-8	400	0.08	0.00	0.00
	800	0.67	0.75	0.00
	1600	1.00	1.00	0.67
	3200	1.00	1.00	1.00
H-8	400	1.00	1.00	1.00
	800	0.92	1.00	1.00
	1600	0.83	1.00	1.00
	3200	1.00	1.00	1.00
S-8	400	1.00	0.33	0.33
	800	1.00	0.67	0.33
	1600	1.00	0.58	0.67
	3200	1.00	1.00	0.67

Table 4.4: Average Maps of each criterion (Average estimated dimensionalities in parentheses).

Dataset	# of nodes	DNML	AIC	BIC
E-8	400	1.000(8.0)	0.625(14.0)	0.625(5.0)
	800	0.750(12.0)	0.556(14.7)	0.833(6.7)
	1600	0.871(9.3)	0.583(14.7)	0.486(3.7)
	3200	1.000(8.0)	1.000(8.0)	0.670(4.0)
H-8	400	0.333(2.0)	0.333(3.2)	0.333(2.0)
	800	0.333(3.5)	0.513(4.3)	0.333(2.0)
	1600	0.431(4.0)	0.958(8.7)	0.333(2.0)
	3200	0.833(6.7)	0.375(17.3)	0.333(3.8)
S-8	400	0.304(15.5)	0.333(3.5)	0.333(2.0)
	800	0.424(13.3)	0.444(3.83)	0.333(2.0)
	1600	0.544(14.3)	0.625(5.3)	0.333(2.5)
	3200	0.708(16.7)	0.736(7.3)	0.333(3.3)

ノードが多い場合、提案手法は高い精度(MAP)で真の次元と曲率を同定.

- 2. 論文共著関係ネットワーク [13]でのリンク予測性能および推定次元の関係.

Table 4.6: Selected dimensionality and curvature of each method.

Network	DNML	AIC	BIC
AstroPh	$\mathbb{H}^{12}_{-0.25}$	$\mathbb{H}^{15}_{-0.25}$	$\mathbb{H}^8_{-0.27}$
HepPh	\mathbb{E}^{16}	$\mathbb{H}^{14}_{-0.32}$	$\mathbb{H}^6_{-0.36}$
Airport	\mathbb{E}^7	\mathbb{E}^7	$\mathbb{H}^3_{-0.73}$
WN-mammal	$\mathbb{H}^4_{-0.69}$	$\mathbb{H}^4_{-0.71}$	$\mathbb{H}^3_{-0.72}$
WN-solid	$\mathbb{H}^4_{-0.69}$	$\mathbb{H}^5_{-0.70}$	$\mathbb{H}^3_{-0.71}$

Table 4.7: Average conciseness of each method.

Network	ϵ_{\max}	DNML	AIC	BIC
AstroPh	0.05	0.484	0.467	0.362
	0.10	0.532	0.484	0.540
HepPh	0.05	0.496	0.398	0.351
	0.10	0.518	0.436	0.544
Airport	0.05	0.390	0.405	0.000
	0.10	0.549	0.550	0.425
WN-mammal	0.05	0.000	0.000	0.000
	0.10	0.416	0.385	0.341
WN-solid	0.05	0.398	0.549	0.080
	0.10	0.637	0.676	0.521

提案手法はリンク予測のAUCを保ちつつ低次元を選択(conciseness).

研究のポイント

- 次元と曲率の同時選択手法構築.
 - 先行研究の少なさ [14].
- 潜在変数モデルおよびDNMLの利用.
 - 潜在変数モデルを用いない場合, Non-identifiability Problemにより符号長の解析計算が非常に困難.
- 人工データ・実データでの性能検証.

[4] P. T. Hung and K. Yamamoto, "Word2vec skip-gram dimensionality selection via sequential normalized maximum likelihood," *Entropy*, vol. 23, no. 8, p. 997, 2021.
[5] Skopek, Ondrej, Octavian-Eugen Ganea, and Gary Bećigneul, "Mixed-curvature variational autoencoders," *8th International Conference on Learning Representations*, 2020.
[6] Nagano, Yoshihiro, et al., "A wrapped normal distribution on hyperbolic space for gradient-based learning," *International Conference on Machine Learning*, PMLR, 2019.
[7] Skopek, Ondrej, Octavian-Eugen Ganea, and Gary Bećigneul, "Mixed-curvature Variational Autoencoders," *International Conference on Learning Representations*, 2019.
[8] Rissanen, Jorma, "Modeling by shortest data description," *Automatica* 14 (1978): 465-471.
[9] Rissanen, Jorma, *Optimal estimation of parameters*. Cambridge University Press, 2012.
[10] Yamamoto, Kenji, "Learning with the Minimum Description Length Principle," Springer Nature, 2023.
[11] K. Yamamoto, "A learning criterion for stochastic rules," *Machine Learning*, vol. 9, no. 2-3, pp. 165-203, 1992.
[12] K. Yamamoto, T. Wu, S. Sugawara, and M. Okada, "The decomposed normalized maximum likelihood code-length criterion for selecting hierarchical latent variable models," *Data Mining and Knowledge Discovery*, vol. 33, no. 4, pp. 1017-1058, 2019.
[13] J. Leskovec and R. Sosić, "Snap: A general-purpose network analysis and graph-mining library," *ACM Transactions on Intelligent Systems and Technology (TIST)*, vol. 8, no. 1, p. 1, 2016.
[14] P. Almagro, M. Boguna, and M. Serrano, "Detecting the ultra low dimensionality of network libraries," *arXiv preprint arXiv:2110.14507*, 2021.