

# 学習数理情報学研究室の紹介

東京大学 大学院情報理工学系研究科  
数理情報学専攻  
山西研究室

<http://www.ibis.t.u-tokyo.ac.jp/>

2024/5/11

大学院入試説明会

参加者はチャットにお名前と所属をお書きください

Please write your name and affiliation to chat.

# 山西研究室の概要

コア技術: **情報論的学習理論**

目標: **ディープナレッジの発見**

基礎理論

潜在的ダイナミクス

潜在構造最適化

予兆情報学

*Sign Informatics*

主要応用

医学応用

経済応用

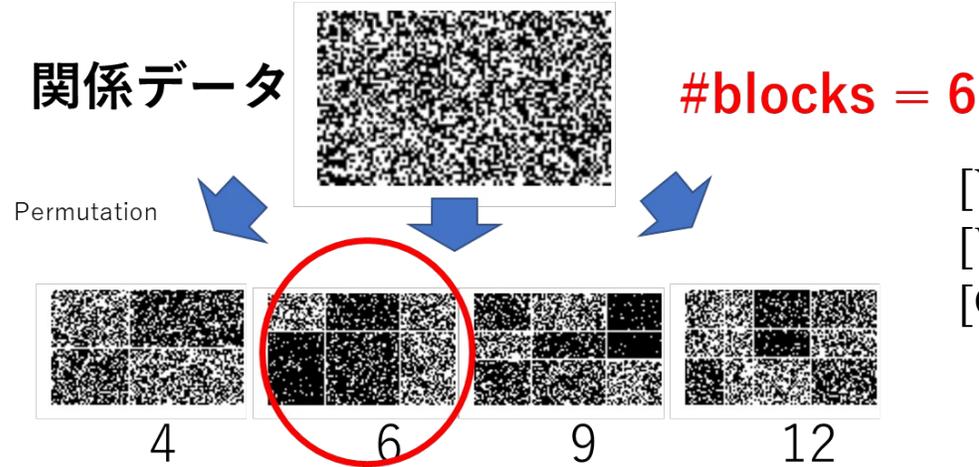
マーケット  
解析

交通リス  
ク解析

# 潜在構造最適化 1

## DNMLによる潜在変数モデル選択

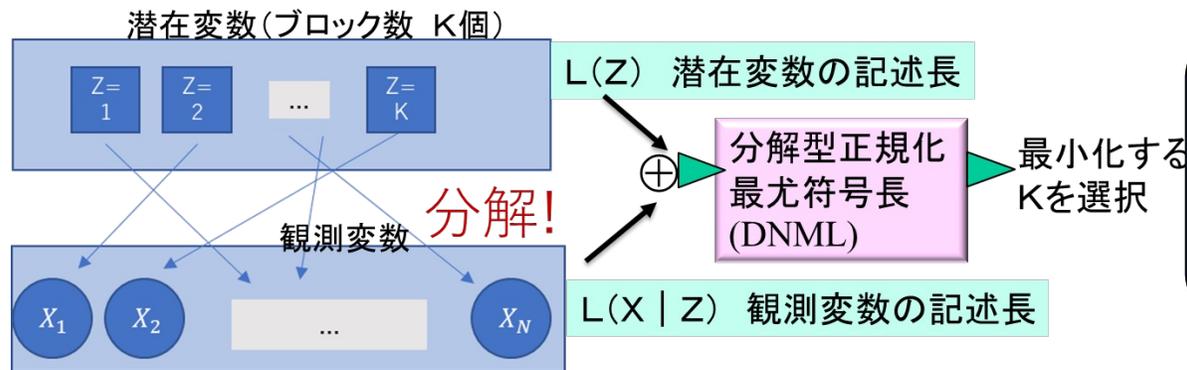
分解型正規化最尤符号長規準 (DNML) で潜在変数の数を最適化



[Yamanishi, Wu, Sugawara, Okada *DAMI* 2019]

[Wu, Sugawara, Yamanishi *KDD* 2017]

[Okada, Yamanishi, Masuda *RSOS* 2019]



- 1) 効率計算可能
- 2) 広い適用可能性
- 3) 高精度かつロバストなモデル選択

$$P(X; K) = \sum_Z P(X, Z; K)$$

観測変数

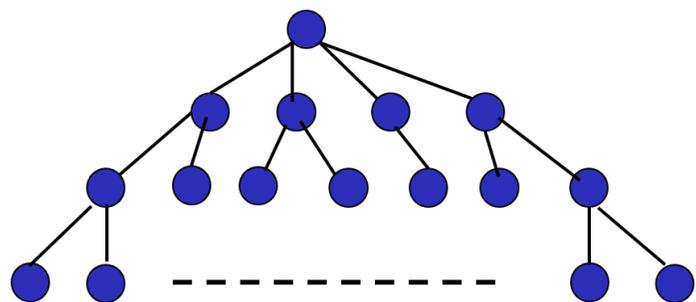
潜在変数

$$\min_K \{L_{\text{NML}}(X|Z; K) + L_{\text{NML}}(Z; K)\}$$

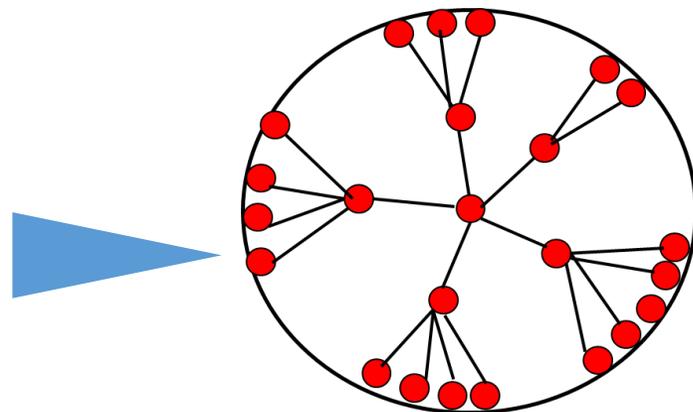
# 潜在構造最適化 2

## グラフの双曲空間埋め込み次元推定と性能解析

階層グラフを埋め込む双曲空間の次元をDNMLで最適推定



階層的グラフ



双曲空間埋め込み

[ Suzuki, Nitanda, Wang, Xu, Yamanishi  
Cvazza, NeurIPS 2022]

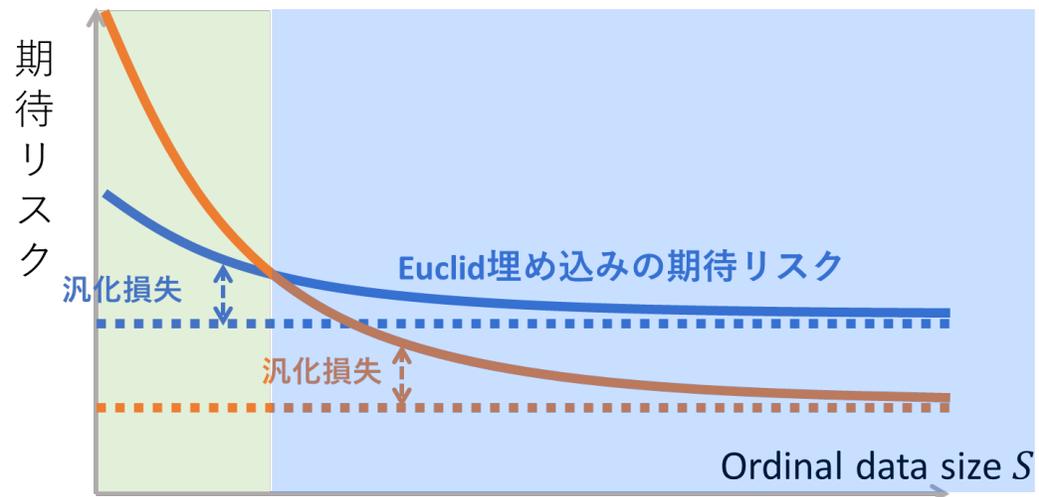
[ Suzuki, Nitanda, Suzuki, Wang, Tian,  
Yamanishi ICML2023]

### 次元選択

DNML 符号長規準 [Yuki, Ike, Yamanishi ICDM2022, KAIS2023]

$$\min_d \mathcal{L}_{\text{DNML}}(y, z) = \min_d \{ \mathcal{L}_{\text{NML}}(y|z; d) + \mathcal{L}_{\text{NML}}(z; d) \}$$

$y$ : グラフ,  $z$ : 双曲埋め込み,  $d$ : 次元



# 潜在構造最適化 3

## 埋め込み空間選択

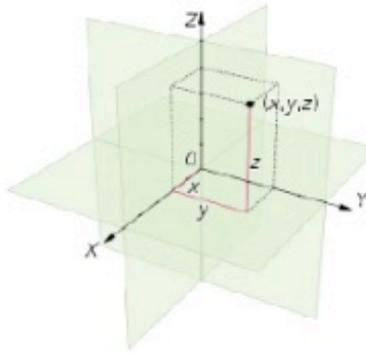
グラフ構造に最適な埋め込み空間と曲率をMDL原理に基づいて選択

Spherical Space ( $K>0$ )



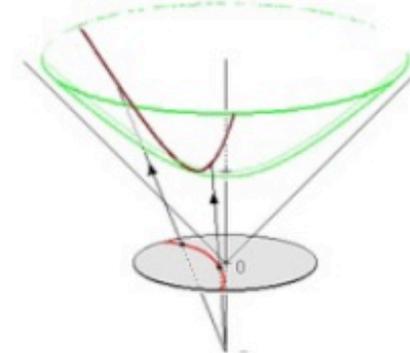
<https://en.wikipedia.org/wiki/Sphere>

Euclidean Space ( $K=0$ )



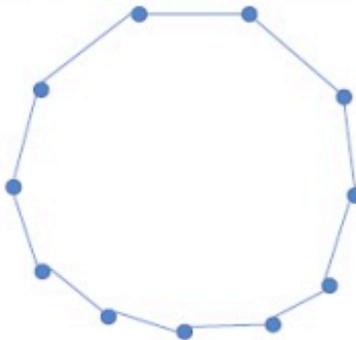
[https://en.wikipedia.org/wiki/Euclidean\\_space](https://en.wikipedia.org/wiki/Euclidean_space)

Hyperbolic Space ( $K<0$ )

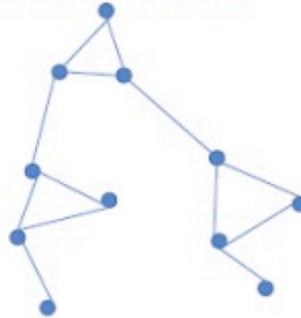


[\\*https://en.wikipedia.org/wiki/Hyperboloid\\_model](https://en.wikipedia.org/wiki/Hyperboloid_model)

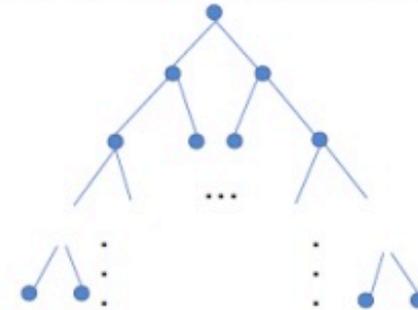
Cyclic structure (Gu+ 2019)



Flat structure



Tree-like structure (Krioukov+ 2010 etc)

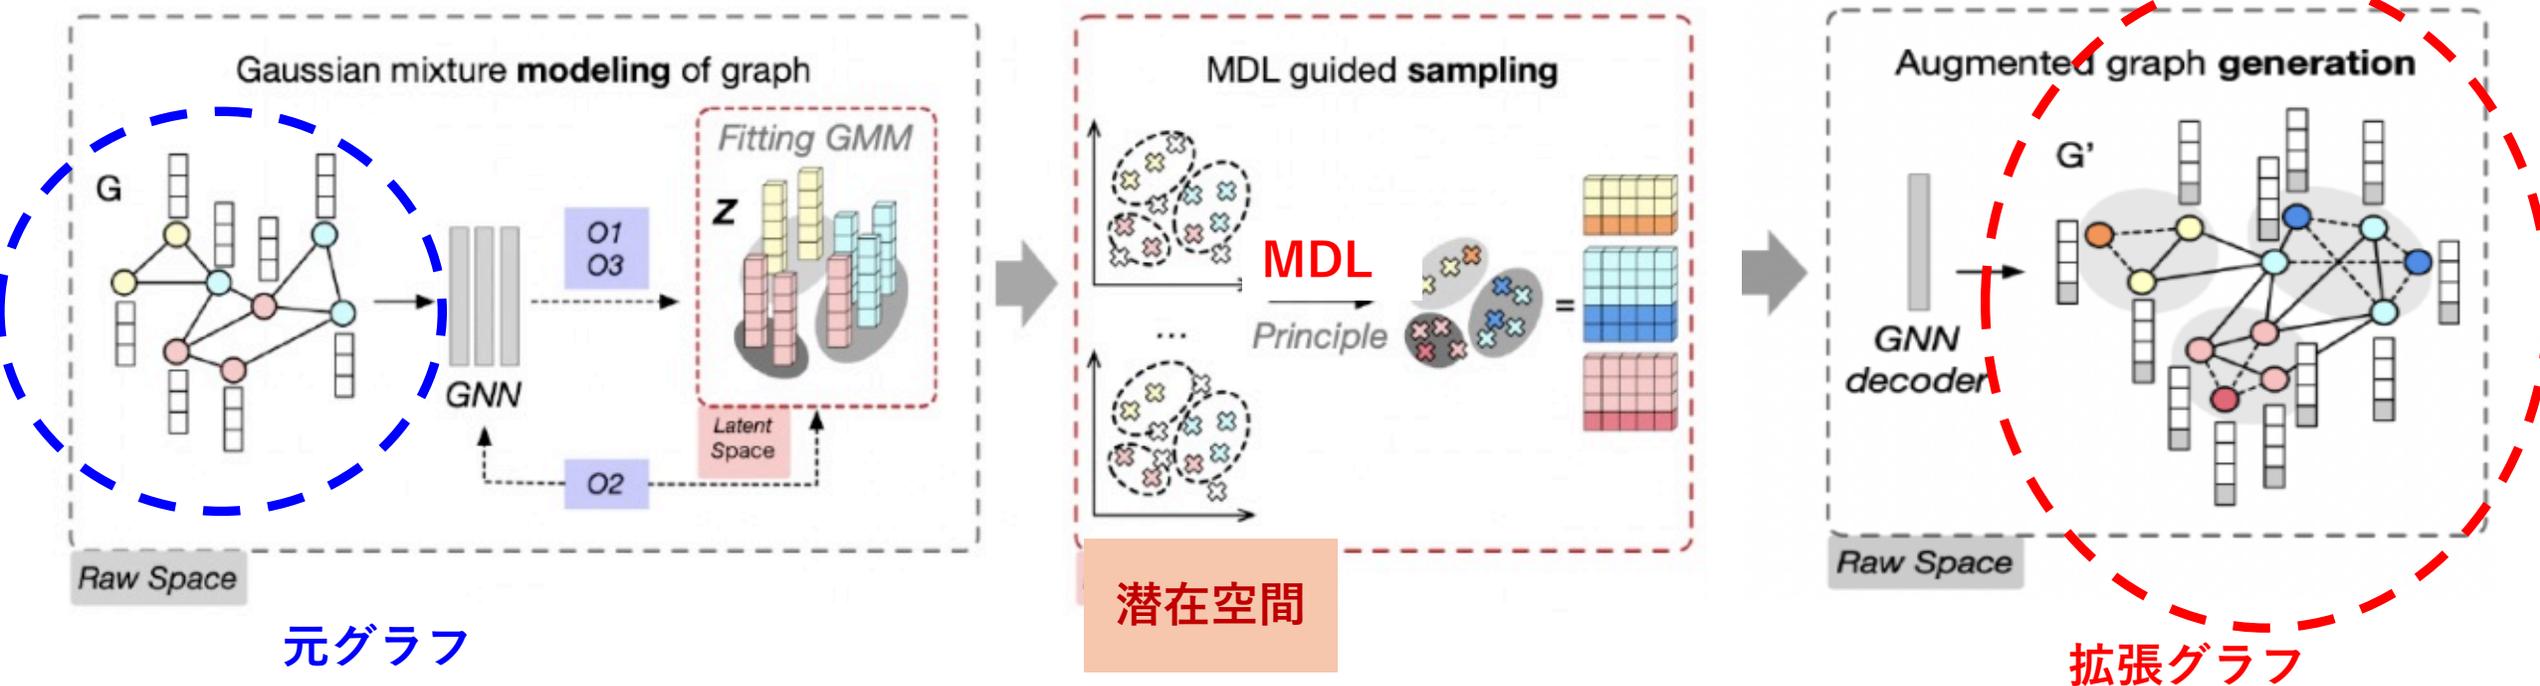


# 潜在構造最適化 4

## GMMに基づくグラフ拡張(GMM-based Graph Augmentation)

グラフを潜在空間でGMMモデリング、DNML規準の下でサンプリングに基づくグラフ拡張

[Li, Xu, Yamanishi ICDM2023]



Embedding by GNN  
+ GMM modeling

Sampling s.t. Description  
Length is not so different

Decoding of the generated  
GMM to get augmented graph

# 潜在的ダイナミクス1

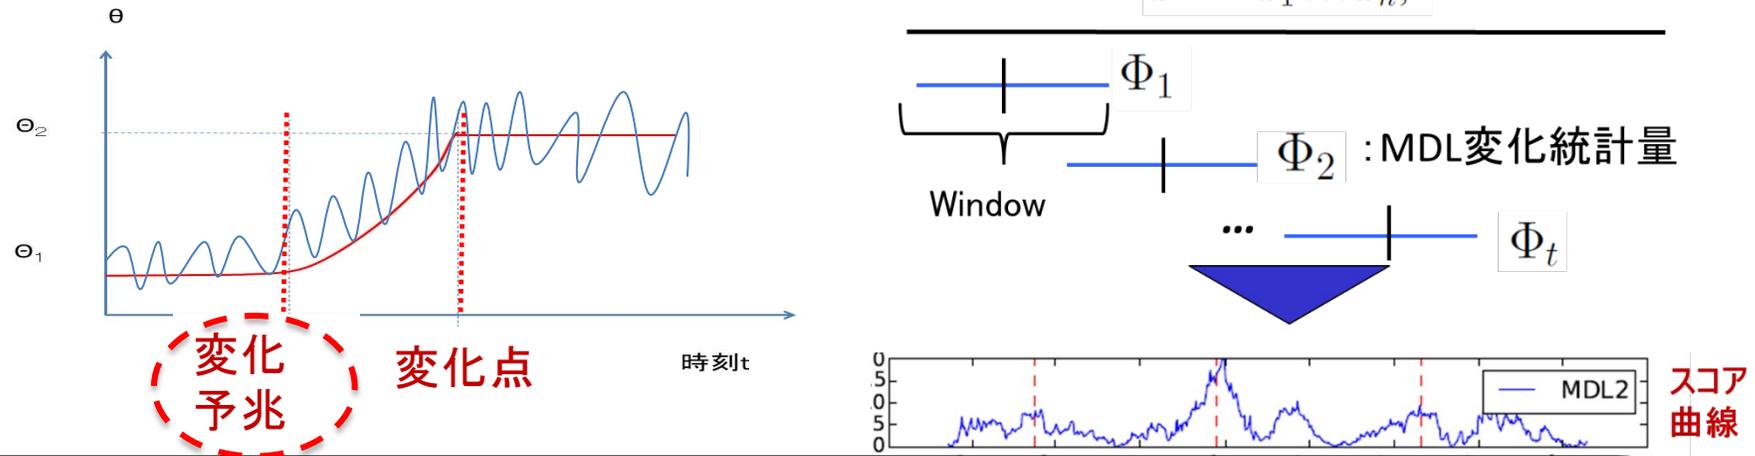
## MDL変化統計量による変化予兆検知

データ圧縮度合いで漸進的変化の開始点(予兆)を検知

[Yamanishi, Miyaguchi BigData2016] [Kaneko, Miyaguchi, Yamanishi BigData2017]

[Yamanishi, Fukushima IEEE Trans Inform Theory 2018]

$$x^n = x_1 \dots x_n,$$



技術コア: MDL変化統計量によるオンライン変化検知を提案

MDL: Minimum Description Length

$$\Phi_t = \min_M L_{\text{NML}}(x_1^n; M) - \min_{M_1, M_2} \{L_{\text{NML}}(x_1^t; M_1) + L_{\text{NML}}(x_{t+1}^n; M_2)\}$$

変化した場合と  
しない場合の  
記述長の差

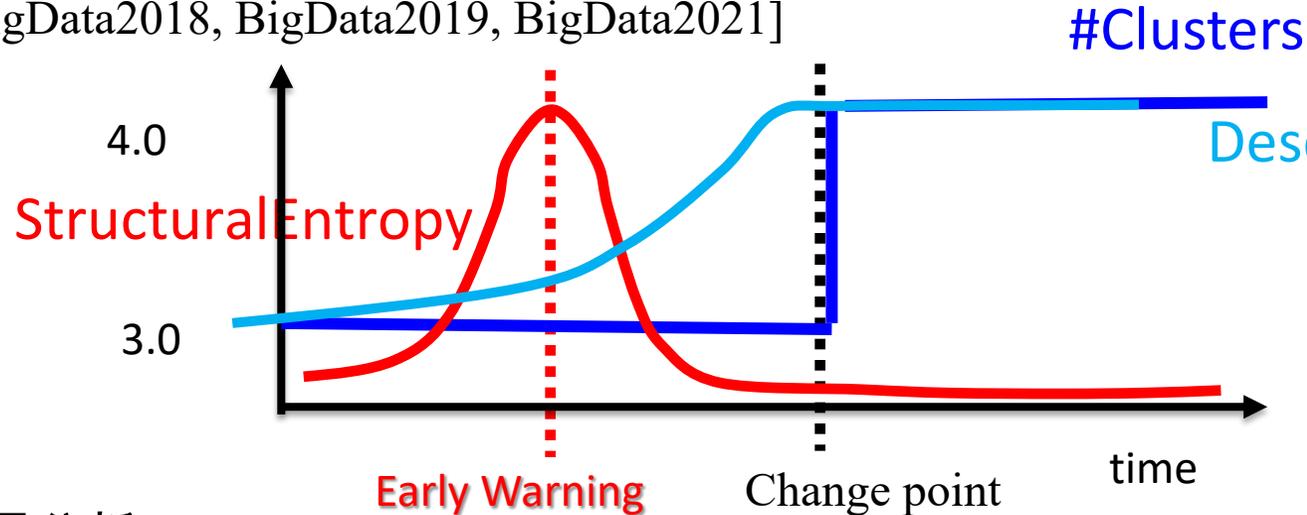
- ⇒
- ・固定窓で移動計算、漸進的変化検知 [BigData 2016]
  - ・可変窓で移動計算、検知精度を大幅改善 [BigData 2017]
  - ・工場のボイラー事故の予兆を検知(東レとの実証実験)

# 潜在的ダイナミクス2

## 潜在構造変化予兆検知

連続量(構造エントロピー、Ddim)でクラスタリング構造変化の予兆を検知

[Hirai Yamanishi BigData2018, BigData2019, BigData2021]



$$Ddim_t = \sum_k p(k|\mathbf{x})k$$

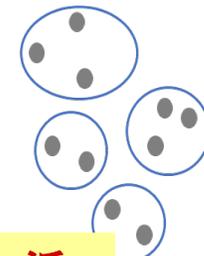
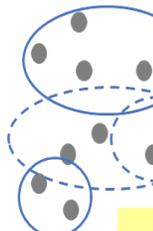
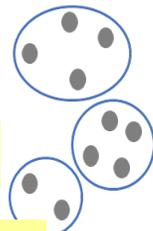
[Yamanishi Hirai Appl.Int. 23]

ビール購買分析

発泡酒派

地ビール派

プレミアム派



ベルギー派  
の登場

t

t+1

t+2

t+3 time

マーケット構造  
変化予兆検知  
電力消費パタン  
変化予兆検知  
で有効性検証

Structural Entropy

[Hirai Yamanishi Bigdata18]

$$H_t = - \sum_k p(k|\mathbf{x}) \log p(k|\mathbf{x}_t) \quad p(k|\mathbf{x}_t) = \frac{\exp(-\beta L_{\text{NML}}(\mathbf{x}_t; k))}{\sum_{k'} \exp(-\beta L_{\text{NML}}(\mathbf{x}_t; k'))}$$

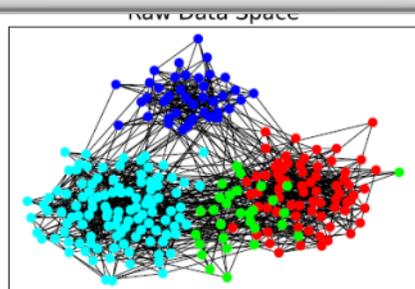
# 潜在的ダイナミクス3

## ネットワーク変化検知

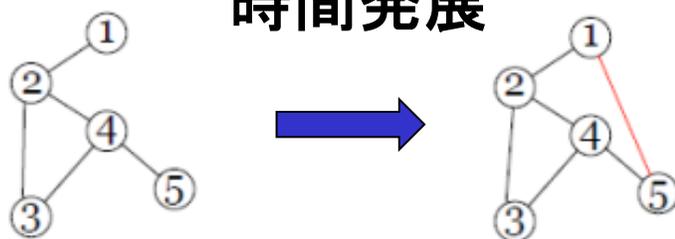
「Lin, Xu, Yamanishi *IEEE TKDE* 2023」

**RWiLS: グラフを潜在空間に埋め込み、ランダムウォークの定常ベクトルを変化検知**

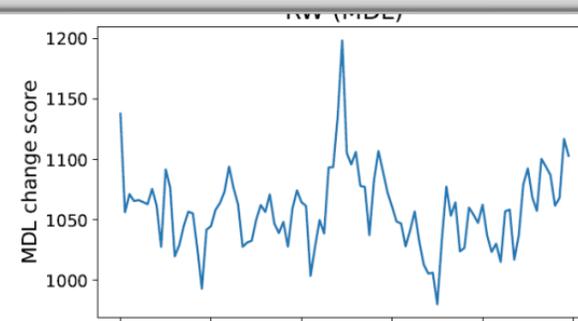
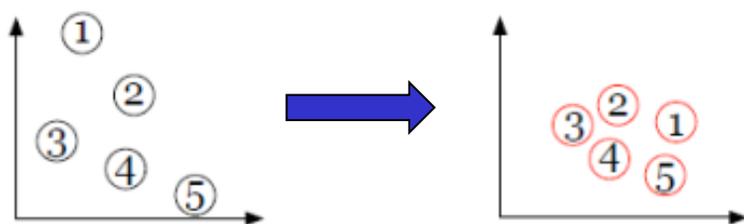
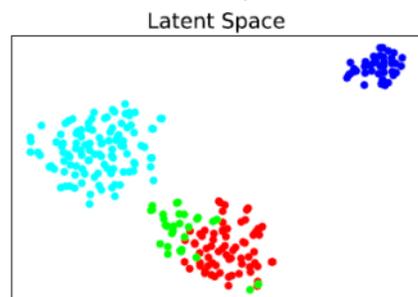
実空間



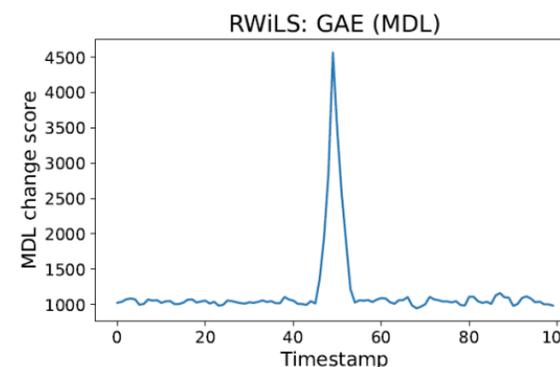
時間発展



潜在空間



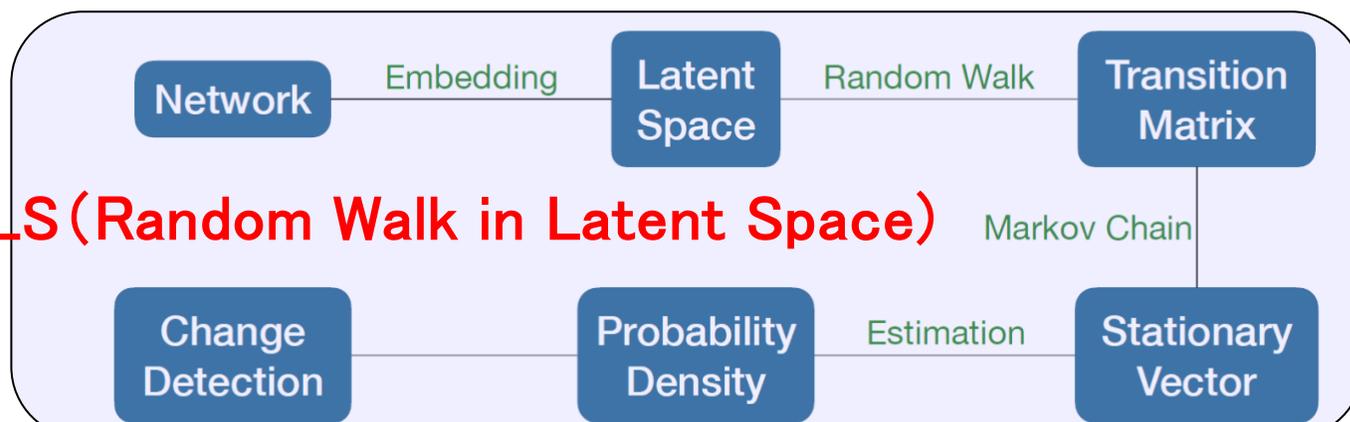
実空間の  
変化検知



潜在空間の  
変化検知

よりロバスト

**RWiLS (Random Walk in Latent Space)**

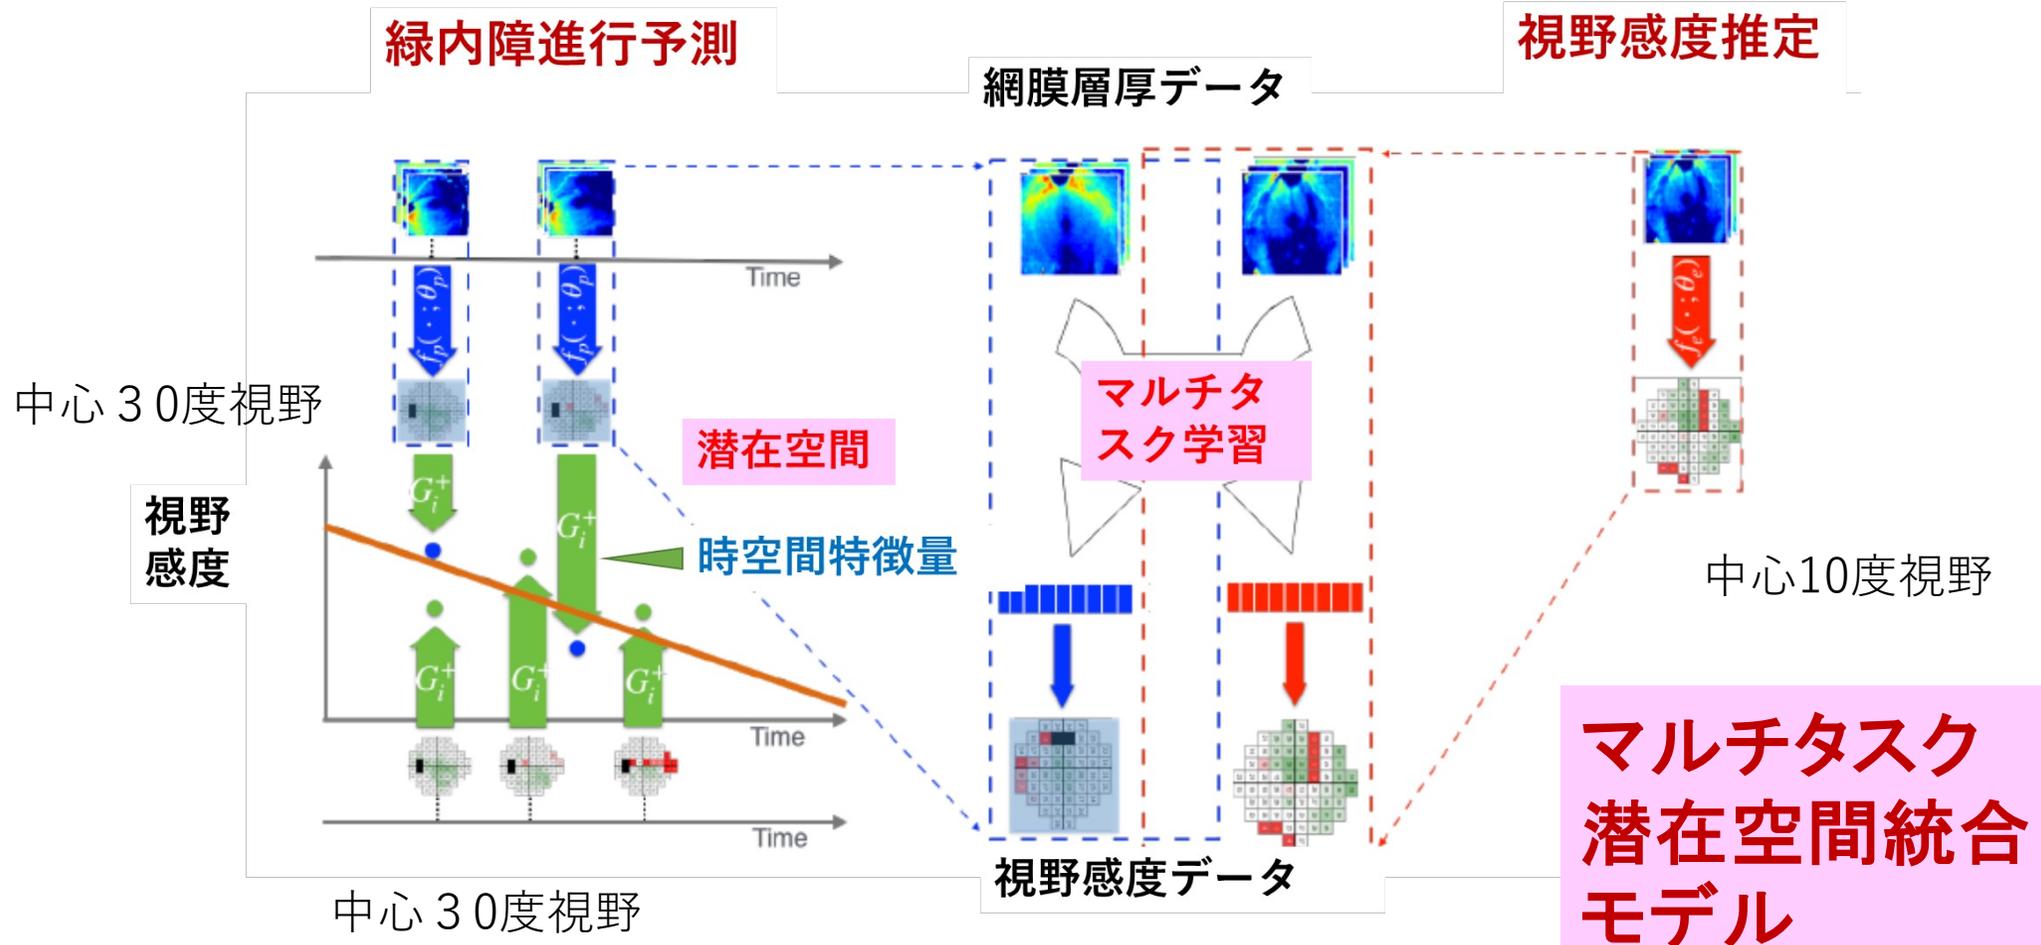


$\Delta d_{exp}$	0.01	0.1	1	10
DynGEM	0.4900	0.3940	0.6007	0.6200
EEC	0.5053	0.5096	0.6165	0.7755
DeltaCon	0.4616	0.6143	0.4313	0.7636
SACPD	0.5084	0.5740	0.7280	0.7276
LAD	0.5206	0.5631	0.5208	0.5948
RWiLS(MDL) with DeepWalk	0.8005	0.9433	0.9443	0.9600
RWiLS(KL) with DeepWalk	0.8002	0.9395	0.9047	0.8212
RWiLS(MDL) with GAE	0.8660	0.9709	0.9700	0.9687
RWiLS(KL) with GAE	0.9373	0.9462	0.9584	0.8716

# 緑内障進行予測

マルチタスク潜在回帰モデルにより視野感度推定と予測の両方で精度増強

[Xu, Asaoka, Kiwaki, Murata, Fujino, Yamanishi KDD2021]



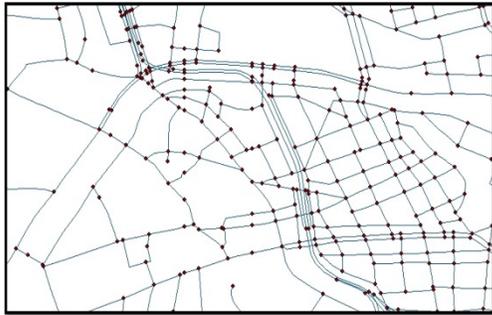
# 交通リスクマイニング

地形データをネットワーク中心性で数値化、危険パターンを特徴づけ

[Kobayashi, Lee, Matsushima, Yamanishi BigData 2017]

[Lee, Matsushima, Yamanishi DAMI 2019]

地形  
データ



高速パターンマイニングに基づく分類

$$\min_{\mathbf{w}} C \sum_{i=1}^m L \left( \sum_{\phi \in \Phi^{(k)}} w_{\phi} \phi(\mathbf{x}_i), y_i \right) + \|\mathbf{w}\|_1$$

ただし,  $L(f(\mathbf{x}), y) = \log(1 + \exp(-yf(\mathbf{x})))$

Network中心性  
で数値表現  
(次数、近傍ノード数、  
ページランク、近傍中心  
性、平均リンク数 etc)



低コストデータ



・危険パターンの抽出  
・潜在的危険個所の  
特定

ビッグデータから  
コンパクトなパタン  
を高速に抽出

2021年1月7日

損害保険ジャパン株式会社

SOMPOリスクマネジメント株式会社

## 自動車事故における自動事故判定に関するAI技術の開発 ～ドライブレコーダーを活用した自動事故判定による事故対応の高度化～

損害保険ジャパン株式会社（代表取締役社長：西澤 敬二、以下「損保ジャパン」）、SOMPOリスクマネジメント株式会社（代表取締役社長：桜井 淳一、以下「SOMPOリスクマネジメント」）は、安全運転支援のための情報技術活用の研究成果として、「機械学習による自動事故判定技術」を開発したのでお知らせします。本技術の開発にあたり、国立大学法人東京大学 大学院情報理工学系研究科 数理情報学専攻 山西 健司教授（以下、「東京大学・山西教授」）に技術支援をいただきました。

# オンライン凸最適化とその応用

## オンライン凸最適化

逐次的に凸損失関数が得られる環境下で  
実行可能領域から適切に点を選択し累積損失を最小化する問題

## 幅広い応用先

オンライン凸最適化  
[Tsuchiya, S.Ito 2024]

確率的最適化  
▶ 深層学習の学習に不可欠な確率的勾配降下法, AdaGrad

オンライン分類問題・回帰問題 [Sakaue, Bao, Tsuchiya, Oki 2024]

バンディット問題, 部分観測問題 [次のページ]  
▶ 不確実な環境下での逐次的意思決定問題

赤枠：近年の研究対象

オンライン制御理論 [K.Ito, Tsuchiya 2024]  
▶ 現代制御理論とオンライン最適化の融合

# 多腕バンディット問題

## 多腕バンディット問題

$k$  個のスロットマシンが用意され、

その中から1つ選び合計  $T$  回プレイし、累積損失を最小化する問題

目標：累積損失の最小化 = **リグレット**  $R_T$  の最小化

$$R_T = \mathbb{E} \left[ \sum_{t=1}^T \ell_{t,A_t} - \sum_{t=1}^T \ell_{t,a^*} \right], \quad a^* = \operatorname{argmin}_{a \in [k]} \sum_{t=1}^T \ell_{t,a}$$

各時刻の損失ベクトル  $\ell_1, \dots, \ell_T \in [0,1]^k$  が決定される

各ラウンド  $t = 1, \dots, T$  :

1. アーム  $A_t \in [k] := \{1, \dots, k\}$  を選択
2. アーム  $A_t$  の損失  $\ell_{t,A_t} \in [0,1]$  を被り,  $\ell_{t,A_t}$  のみ観測

## 研究成果

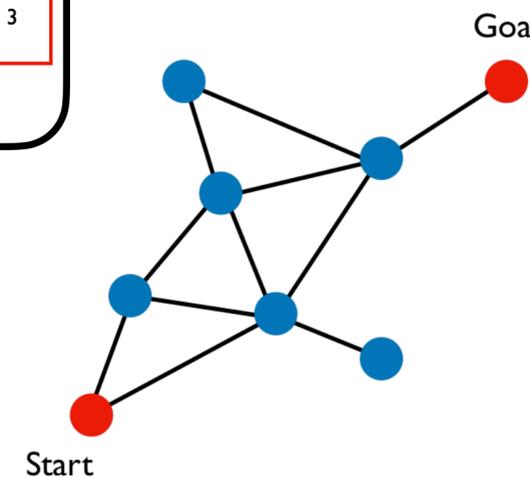
1. 損失のスパース性を活用可能な多腕バンディットアルゴリズム  
[Tsuchiya, S.Ito, Honda NeurIPS2023]

## 2. 組合せバンディット問題における両環境最適アルゴリズム

[Tsuchiya, S.Ito, Honda AISTATS2023]

## 3. 文脈付バンディット問題における両環境最適アルゴリズム

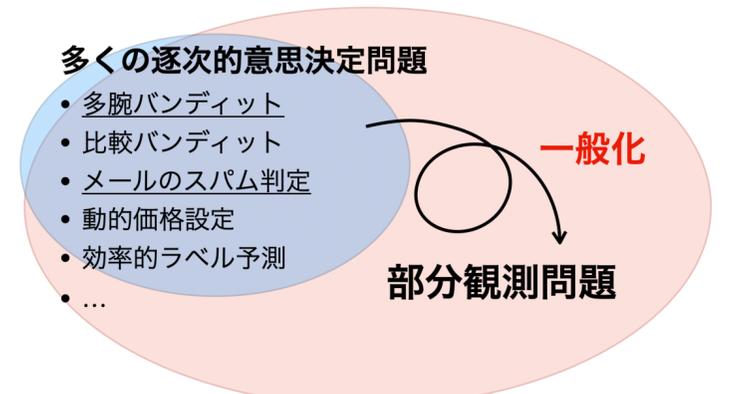
[Kuroki, Rumi, Tsuchiya, Vitale, Cesa-Bianchi AISTATS2024]



# 部分観測問題

## 部分観測問題

間接的フィードバックに基づく逐次的意思決定問題の非常に一般的な枠組み



### 動的価格設定の例

<p><b>プレイヤー (= ホテルのオーナー)</b></p> <p><math>t = 1</math>日目</p> <p>ホテルのオーナー <span style="border: 1px solid black; padding: 2px;">宿泊料 4,000円</span></p> <p><math>t = 2</math>日目</p> <p>HOTEL   <span style="border: 1px solid black; padding: 2px;">宿泊料 8,000円</span></p> <p>ホテル1泊の宿泊料を決定 {1000円, ..., 1000 × k円}</p> <p><math>t = \dots</math></p>	<p><b>敵対者</b> 利用者の 内部状態 <math>x_t</math> (= 評価額)</p> <p></p> <p>宿泊料 ≤ 9,000円 なら利用</p> <p></p> <p>宿泊料 ≤ 5,000円 なら利用</p>	<p>(機会) 損失</p> <p>9,000 - 4,000 = 5,000円</p> <p><math>c</math> 円 (定数) (<math>\because 5000 - 8000 &lt; 0</math>)</p>	<p><b>フィードバック</b></p> <p>宿泊する</p> <p>宿泊しない</p>
	<del>👁️👁️</del>	<del>👁️👁️</del>	👁️👁️

販売者は、フィードバック (宿泊する or 宿泊しない) のみ観測可能

フィードバックのみから、全体の損失を最小化する (= 全体の報酬を最大化する) ことを目指す

### 研究成果

1. 問題の属する**最小クラスの難しさ**に依存したリグレット上界  
[Tsuchiya, S.Ito, Honda NeurIPS2023]
2. **グラフバンディット問題**における両環境最適アルゴリズム  
[S.Ito, Tsuchiya, Honda NeurIPS2022]
3. 部分観測問題における両環境最適アルゴリズム  
[Tsuchiya, S.Ito, Honda ALT2023]