

# 位相的データ解析への統計的機械学習アプローチ

福水 健次

数理・推論研究系 教授

(東北大・AIMR・平岡裕章先生, 草野元紀氏との共同研究)

## ■ 位相的データ解析 (TDA)

データの位相的・幾何的情報を抽出するための新しい方法論

キーテクノロジー = **パーシステントホモロジー**


(Edelsbrunner et al 2002; Carlsson 2005)

• 様々な応用



• **ホモロジー群** 位相的不変量

図形は、三角形 (単体) の集まりで記述する ⇒ 代数的な扱い。




• **ホモロジー群**: 位相的不変量として「穴」を群として表す。

- 0次元 = 連結成分  $H^0(X)$
- 1次元 = リング  $H^1(X)$
- 2次元 = 空洞 (cavity)  $H^2(X)$  ...

ホモロジー群の**生成元**: 連続的に移り合えない「穴」の代表元

• **統計的推論における位相情報の利用**


有限データからの位相の特定は容易ではない。



• **パーシステントホモロジー** すべての  $\epsilon$  を同時に考える。


- 点集合  $X = \{x_i\}_{i=1}^m \subset \mathbf{R}^d$ ,  $X_\epsilon := \cup_{i=1}^m B_\epsilon(x_i)$
- 位相空間の増大列  $\mathcal{X}: X_{\epsilon_1} \subset X_{\epsilon_2} \subset \dots \subset X_{\epsilon_L}$  ( $\epsilon_1 < \dots < \epsilon_L$ )
- 異なるパラメータ  $\epsilon_i < \epsilon_j$  に対し, ホモロジー生成元の関係づけが可能 (新たに発生, 継続, 消滅).
- 各生成元の発生と消滅時刻が定まる.

1次ホモロジー群  $H_1(X)$  の生成元の発生と消滅



• **パーシステント図 (PD, 生成, 消滅の表現)**


各PH生成元の発生(b), 消滅(d)時刻を, 2Dグラフ上の点 (b,d) で表したものを。



複雑な幾何的データの特徴ベクトル / 記述子として使おう!

## ■ カーネル法によるパーシステント図のベクトル化

• PDのデータ解析



• **カーネル法によるベクトル化**

PD = 離散測度と思う  $\mu_D := \sum_{x_i \in D} \delta_{x_i}$   $D = \{x_i\}$  生成・消滅時刻

PDのRKHSへの埋め込み

$$\mathcal{E}_k: \mu_D \mapsto \sum_i k(\cdot, x_i) \in H_k, \quad \text{e.g. } \sum_i \delta_{x_i} \mapsto \sum_i \exp\left(-\frac{\|y-x_i\|^2}{2\sigma^2}\right)$$

• **Persistence Weighted Gaussian Kernel**


アイデア: 対角線に近い生成元はノイズの可能性が高い ⇒ 重みを小さく

$$k_{PWG}(x, y) = w(x)w(y)\exp\left(-\frac{\|y-x\|^2}{2\sigma^2}\right)$$

• 重み関数  $w(x) := \arctan(C \text{Pers}(x)^p)$  ( $C, p > 0$ )

• ベクトル化により既存の統計的手法が利用可能

• 安定性定理が成立 (Kusano et al ICML2016) 点集合がHausdorff距離で微小に変化したとき, そのベクトル表現もRKHSの距離で微小にしかならない。



## ■ 応用

● **シリカ(SiO2)の液相-ガラス相転移**


• 目的: 液相からガラス相に転移する温度を特定したい。

• データ: SiO2分子動力学 (MD) シミュレーション

(Nakamura et al 2016 PNAS)




- 温度を変えて80セットの3次元原子配置データ (スナップショット) を取得
- 原子の3次元配置データから, PDを計算。




• 提案法: PDのベクトル化に対する変化点検出問題として転移点を推定

変化点検出

$$KFDR_{n, \ell, \gamma}(D)$$



検出された変化点 = 3100K  
物理的方法: [2000K, 3500K]



● **時系列解析**


• タンパク質 (1BDD) のMDシミュレーションデータ (岐阜大・一宮尚志氏提供) 60 Ca. 初期状態は伸ばした状態。

• カーネル法によるベクトル時系列をSVDによりモード分解

$$(\mu_1, \dots, \mu_t) = UTV^T$$

$U$ : 空間固有ベクトル,

$V$ : 時間固有ベクトル



カーネル主成分分析による3次元プロット

変化点  $t = 670-700$

参考文献 Kusano, G., Fukumizu, K., Hiraoka, Y. (2018) Kernel method for persistence diagrams via kernel embedding and weight factor. *Journal of Machine Learning Research*