

チーム概要 :

大自由度・高次元な
データ構造を数学的に理解

データ構造 (因果構造など)
を解析する理論の構築

基礎的研究

- 高次元統計学
- 過剰パラメータ理論
- 深層学習の数理

応用的研究

- 因果推論
- 意志決定論
- 大規模データ解析

基礎的研究：高次元統計・深層モデルの解析

問題：複雑なランダム高次元行列の期待値推定

→ 従属性や確率的な不安定性の元での平均収束

$M_1, \dots, M_n \in \mathbb{R}^{p \times p}$: ランダム行列の列

列の(弱)従属性

$$\sup_{g \in \text{Lip}} |\mathbb{E}[g(M_{\ell+1}, \dots, M_n) | \mathcal{F}_\ell] - \mathbb{E}[g(M_{\ell+1}, \dots, M_n)]| \leq \Gamma$$

ランダム行列の裾確率

$$\mathcal{F}_\ell = \sigma(X_1, \dots, X_\ell)$$

$$G(t) = \max_{\ell} \int_t^\infty \mathbb{P}(\|M_\ell\| > u) du$$

アプローチ：変分不等式を用いた摂動評価

→ 高次元性・従属性を制御

$$\mathbb{E}[\exp(\lambda h(M) - \lambda \mathbb{E}[h(M)])] \leq C \exp\left(\frac{\lambda^2 L^2 \sum_{\ell=1}^n (\kappa + \Gamma)^2}{n^2}\right)$$

結果：高次元性に依存しない経験平均の収束

定理 (経験平均の次元フリー収束)

確率 $1 - p(t, \tau)$ 以上で以下が成立:

$$\left\| \frac{1}{n} \sum_{\ell=1}^n M_\ell - \mathbb{E}[M_\ell] \right\| = O\left(\frac{\|\Sigma\|(\tau + \Gamma) \sqrt{\frac{r(\Sigma) + t}{n}} + G(\tau)}{n}\right)$$

経験平均の誤差

次元 p に依存しない誤差

n : 観測行列の数
 $\tau, t > 0$: ハイパラ
 $r(\Sigma) = \frac{\text{Tr}(\Sigma)}{\|\Sigma\|}$: 実効ランク
 $p(t, \tau)$: ある関数

問題：可逆関数を可逆関数で推定

可逆関数を可逆のまま推定する複雑性の定量化

$X \in [0, 1]^2$: 入力, $Y \in [0, 1]^2$: 出力, ε : ノイズ, f_* : 可逆関数

$$Y = f_*(X) + \varepsilon$$

応用例:

Normalizing Flow など
可逆性による生成モデル

自身が可逆な推定量 $\hat{f}(\cdot)$ を構成

アプローチ：ミニマックス可逆リスクレートの解析

$$\text{可逆リスク } R(\hat{f}, f_*) = \mathbb{E} \left[\|\hat{f} - f_*\|^2 + \|\hat{f}^{-1} - f_*^{-1}\|^2 \right]$$

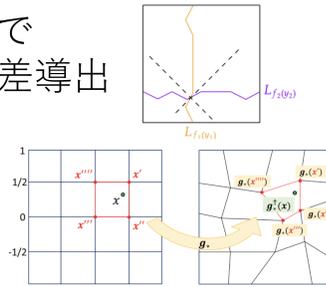
下界: レベルセットの共通部分で

最悪単調関数を構成 → 誤差導出

上界: 可逆推定量の具体的構成

- 入出力空間の格子間写像
- ”ねじれ“の漸近的解消

格子の消失を極限で解消



結果：レート導出と複雑性評価

定理1 (可逆リスクレートの上界)

$$\min_{\hat{f}} \max_{f_*} R(\hat{f}, f_*) = \tilde{O}(n^{-2/(2+d)})$$

可逆性のないレートと同一

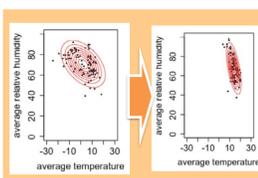
→ 可逆関数は推定の複雑性を
増加させない

応用的研究：機械学習の諸問題への貢献

問題：ガウス分布間回帰

$(\mu_i, \nu_i), i = 1, \dots, n$: 入出力ガウス分布の組
(μ_i, ν_i のそれぞれが \mathbb{R}^d 上の確率分布)

目的: μ_i から ν_i を予測する回帰モデル構築



例: 気候分布回帰

アプローチ：接空間上での線形回帰モデル

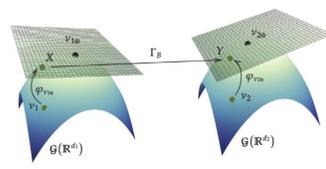
1. 分布空間 (Wasserstein空間) の
接空間に分布を転移

ガウス分布により等長性が保障

2. 接空間 (線型空間) で

共分散行列間の線形回帰

テンソルパラメータを用いた回帰モデリング



分布空間(曲面)から接空間(平面)へ

結果：高速・理論付き回帰モデルの提案

定理 (推定誤差評価)

$$R(T) = \tilde{O}(\sqrt{K(2d)/\sqrt{n}})$$

推定誤差 次元 p に依存しない誤差

n : データ数

$d \geq 2$: 分布の定義域の次元

K : テンソルパラメータのランク

多次元分布間回帰の成功例

トピック：敵対的生成ネットワーク (GAN)

f : 識別器, θ : 生成器, μ_θ : 生成した分布

$\mathcal{V}(f, \mu_\theta)$: 識別目的関数, $\mathcal{J}(\theta; f)$: 生成目的関数

2プレイヤー最適化

$$\max_f \mathcal{V}(f, \mu_\theta), \min_\theta \mathcal{J}(\theta; f)$$

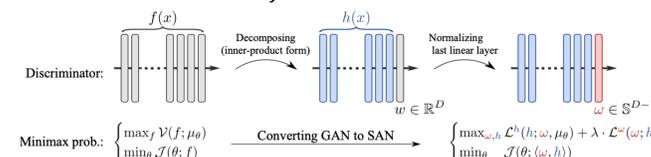
最適化の不安定性を解決する
新しい目的関数の提案

アプローチ：識別器を一様に距離化可能

背景: 最適値以外の識別器 f のもとで識別能力が低下

→ 学習途中の識別器 f でも十分に識別可 (距離化) な設計へ

SANの提案: 識別器 f が単射かつ最適方向を常に満たす目的関数

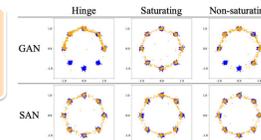


結果：高精度GANであるSANの開発

定理 (距離化可能定理)

SANの識別器は距離化可能

モード崩壊の防止



Rank	Model	FID ↓
1	MDT-XL/2	1.79
2	DIT-XL/2-G++	1.83
3	VIT-XL	2.06
4	StyleSAN-XL	2.14
5	DIT-XL/2	2.27
6	StyleGAN-XL	2.30

ImageNet生成で
GANの中でSOTA