

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: 深層ニューラルネットの予測精度の説明

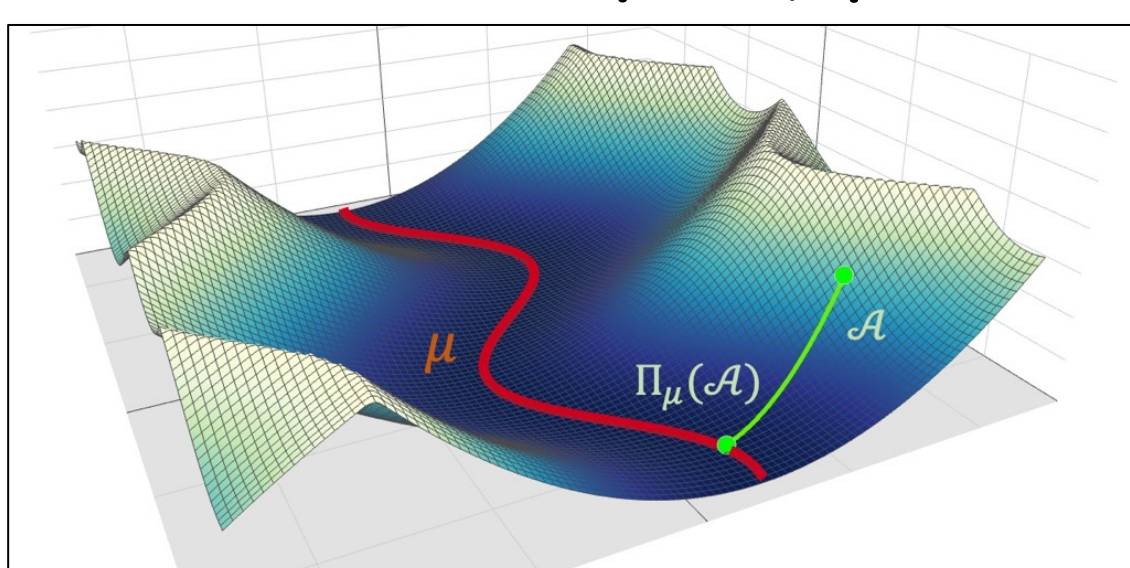
→パラメタ数が多くても過適合しない原理記述

アプローチ: エネルギー曲面を用いた汎化誤差解析

→パラメタがエネルギー曲面の一部に滞留



・局所解
●滞留集合
→学習過程



エネルギー曲面 (等高線)

パラメタを制約する滞留集合と近傍の形状

結果: 曲面上の滞留で過学習を防ぐ様相を記述

定理1 (滞留確率の保証)

減衰する学習率と、T回のパラメタ更新の元で:
 $p^* \geq 1 - c\lambda^{-1} \exp(-T) - T \exp(-RT)$

滞留点に制約される確率

学習が進む(T → ∞)と1に収束

- n: データ数
- θ: パラメタ
- θ̂: 学習したパラメタ
- R(θ): 汎化誤差
- R_n(θ): 経験誤差
- Λ, R: 滞留集合の体積/半径
- d, K: 滞留集合の次元と孤立領域の個数
- h̄: NNの最大幅
- S := sup_{θ ∈ B} ∏_{l=1}^L ||A_l||_S: パラメタ行列A_lのスペクトル積

定理2 (汎化誤差の評価)

確率 p* 以上で以下が成立:

$$R(\hat{\theta}) - R_n(\hat{\theta}) = O\left(\frac{\sqrt{d \log K} + SLR \log^{0.5} \bar{h}}{\sqrt{n}}\right)$$

汎化誤差ギャップ パラメタ数に依存しない誤差

問題: 構造入り高次元線形回帰

パラメタ数が無限まで増加 + ノイズが非独立

X: 入力変数, Y: 出力変数, ε: ノイズ, θ ∈ ℝ^p

Y = ⟨X, θ*⟩ + ξ, ω = E[Xξ] ≠ 0, E[ξ|Z] = 0

Z: 潜在変数, Π: 変換行列, u: 構造ノイズ

$$X = \Pi Z + u$$

ノイズの相関構造を潜在変数を用いて表現

$$\hat{L}(\theta) = \sum_{i=1}^n (Y_i - \langle X_i, \theta \rangle)^2$$

$$\hat{\theta} \in \operatorname{argmin}_{\theta} \hat{L}(\theta)$$

次元 p → ∞, データ数 n → ∞, p/n → κ ∈ (0, ∞)

アプローチ: ガウス不等式による双対問題解析

評価尺度: 射影MSE E[(E[⟨θ̂, X⟩ - ⟨θ*, X⟩|Z])²]

訓練データへの完全適合下での一様上界

$$\leq \sup_{\theta: \hat{L}(\theta)=0} E[(E[⟨\theta, X⟩ - \langle \theta^*, X \rangle | Z])^2]$$

高次元空間

補問量の集合 {θ: L̂(θ) = 0}

凸ガウスミニマックス定理 (CGMT)

W: ガウスランダム行列, g, h: ガウスベクトル

$$\min_a \min_b \langle a, Wb \rangle + \psi(a, b) \approx \min_a \min_b \|a\| \langle g, b \rangle + \|b\| \langle h, a \rangle + \psi(a, b)$$

結果: 一致推定可能性を証明

定理1 (誤差収束の上界)

Xの分布制約と直交条件のもとで

$$\|\hat{\theta} - \theta^*\|_{\Xi}^2 = O\left(\psi(\|\Sigma_u^+ \omega\| + \|\theta^*\|) \sqrt{\frac{\operatorname{tr}(\Xi)}{n}}\right)$$

ω: 相関パラメタ

Ξ := PE[ZZ^T]Π^T: 潜在共分散行列

Σ_u := E[uu^T]: 構造ノイズ共分散

高次元・非独立ノイズでも固有ベクトルの構造のもとで一致推定が可能に

応用的研究: 機械学習の諸問題への貢献

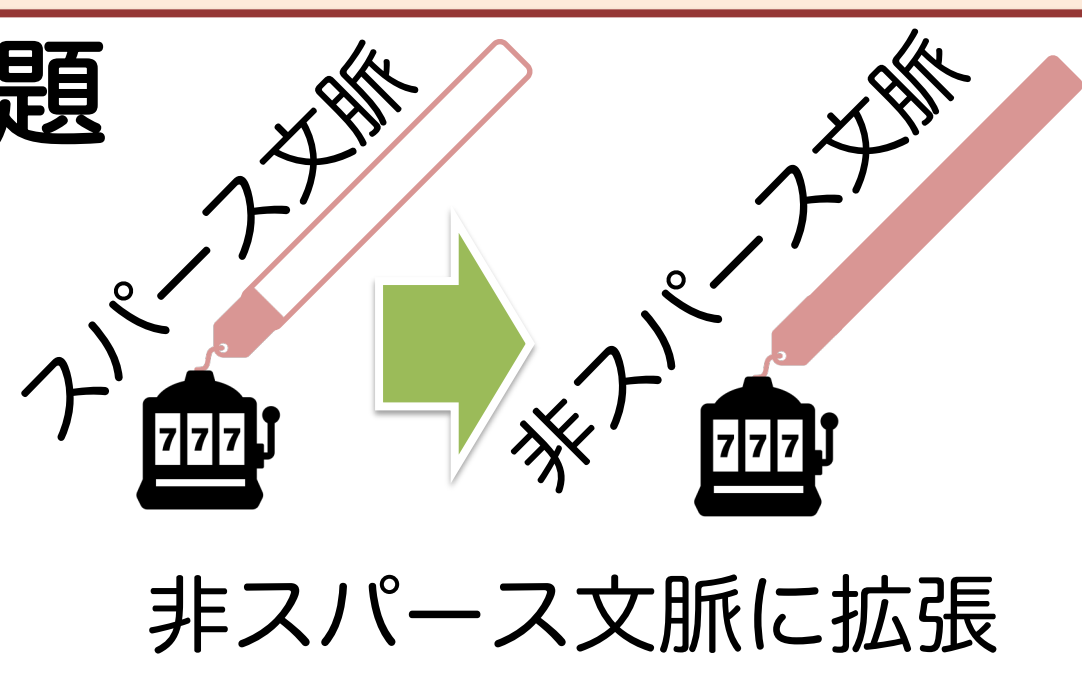
問題: 高次元文脈バンディット問題

X⁽ⁱ⁾(t): 腕iの文脈ベクトル (時刻t)

(平均ゼロ、共分散 Σ⁽ⁱ⁾ = E[X⁽ⁱ⁾(X⁽ⁱ⁾)^T])

選択I(t)の報酬(θ^(k) ∈ ℝ^p: 次元 p → ∞)

$$Y^{(i)}(t) = \langle X^{(i)}(t), \theta^{(i)} \rangle + \xi(t)$$




非スパース文脈に拡張

アプローチ: 共分散Σ⁽ⁱ⁾の構造を実効ランクで記述

数学的ツール: 実効ランク

λ_j⁽ⁱ⁾: Σ⁽ⁱ⁾のj番目に大きい固有値

$$r_k(\Sigma^{(i)}) := \frac{\sum_{j>k} \lambda_j^{(i)}}{\lambda_{k+1}^{(i)}}, R_k(\Sigma^{(i)}) = \frac{(\sum_{j>k} \lambda_j^{(i)})^2}{\sum_{j>k} (\lambda_j^{(i)})^2}$$



高次元で有効なランク概念 → 戦略の誤差記述に有効

結果: 高次元設定で有効戦略の開発とその誤差保証

```
Algorithm 1 Explore-then-Commit (ETC)
Require: Exploration duration T_0
for t = 1 to T_0 do
  Observe X^{(i)}(t) for all i in [K].
  Choose I(t) = argmax_{i in [K]} J(i, t).
  Receive a reward Y^{(i)}(t).
end for
for i in [K] do
  \hat{\theta}^{(i)} = (X^{(i)})^T (X^{(i)} X^{(i)})^{-1} Y^{(i)}.
end for
for t = T_0 + 1 to T do
  Observe X^{(i)}(t) for all i in [K].
  Choose I(t) = argmax_{i in [K]} \langle X^{(i)}(t), \hat{\theta}^{(i)} \rangle.
  Receive a reward Y^{(i)}(t).
end for
```

定理 (期待リグレット評価)

α > 0

Σがある共分散構造を持つとき、T回の試行のもとで

$$R(T) = \tilde{O}(T^\alpha K^{2/3}) \text{ かつ } R(T) = \tilde{\Omega}(T^\alpha)$$

期待リグレット上界

期待リグレット下界


問題: 非線形な操作変数回帰モデル

X: 入力変数, Y: 出力変数, ε: ノイズ

$$Y = f(X) + \varepsilon$$

Z: 操作変数, v: 構造ノイズ

$$X = t(Z) + g(\varepsilon) + v$$



入力変数とノイズが相関 → 操作変数を用いて対処

アプローチ: カーネル関数によるU統計量変換

最大モーメント制約による損失関数 (H_k: 再生核ヒルベルト空間)

$$R_k(f) = \sup_{f \in H_k} (E[(Y - f(X))h(Z)])^2$$

再生性を用いた書き換え ((Y', X', Z'): iid copy)

$$R_k(f) = \sup_{f \in H_k} E[(Y - f(X))(Y' - f(X'))k(Z, Z')]$$

U統計量で推定 → 経験平均

結果: 予測精度と解釈性 (検定) の両立


定理 (漸近分布への収束)

$$\sqrt{n}(\hat{f} - f_0^*) \rightarrow_d \nabla S(G^*)$$

推定誤差 ガウス過程の線形変換

漸近分布の導出 → 統計的検定を開発

年齢と栄養価の死亡率への影響



非線形性による精度向上

Selected Papers

M.Imaizumi, J.Schmidt-Hieber (2023), "On Generalization Bounds for Deep Networks Based on Loss Surface Implicit Regularization", IEEE Transaction on Information Theory, 69(2).

T.Tsuda, M.Imaizumi (2024+), "Benign Overfitting of Non-Sparse High-Dimensional Linear Regression with Correlated Noise", arXiv, R&R.

R.Zhang, M.Imaizumi, B.Schölkopf, K.Muandet (2023), "Instrumental Variable Regression via Kernel Maximum Moment Loss". Journal of Causal Inference, 11(1).

J.Komiyama, M.Imaizumi (2023), "High-dimensional Contextual Bandit Problem without Sparsity", Advances in Neural Information Processing Systems.

A. Okuno, M.Imaizumi (2024), "Minimax Analysis for Inverse Risk in Nonparametric Planer Invertible Regression", Electronic Journal of Statistics.