




数理最適化（主に連続最適化）に関する研究

機械学習やデータマイニングから生じる最適化問題をうまく解き、実社会の問題解決に役立てたい

チームの強み：

- 大規模問題に対するランダム射影を用いた効率的解法
- 非凸最適化問題に対する理論保証つき解法
- 制約付き最適化問題に対する効率的解法

機械学習やデータマイニング



数理最適化問題

$$\begin{aligned} \min. & f(x) \\ \text{s.t.} & g_1(x) \leq 0, \\ & g_2(x) \leq 0, \\ & \dots \end{aligned}$$

解法研究 (例):

- ランダム射影法
- 非平滑・非凸最適化法
- 制約付き最適化法

チームの得意とするところ

Riemann多様体上の2段階最適化 [Han, Mishra, Jawanpuria, Takeda, NeurIPS, 2024]

考える問題 多様体上の2段階最適化問題

$$\min_{x \in \mathcal{M}_x} F(x) := f(x, y^*(x)) \quad \text{s.t. } y^*(x) = \arg \min_{y \in \mathcal{M}_y} g(x, y)$$


- $\mathcal{M}_x, \mathcal{M}_y$: Riemann多様体
- $f, g: \mathcal{M}_x \times \mathcal{M}_y \rightarrow \mathbb{R}$: 平滑
- $g(x, y)$: y に関して測地的強凸

本研究の貢献

- ✓ Hesse作用素の逆作用素・共軛勾配法・Neumann級数・自動微分を利用した**Riemann超勾配の推定**
- ✓ **Riemann超勾配の推定誤差**の分析
- ✓ Riemann超勾配を用いて2段階最適化問題を解く **アルゴリズムの収束性の保証**の分析

数値実験

(1) Riemann超勾配を推定する4手法の比較



(2) 教師なしドメイン適用問題

1段階最適輸送問題としての定式化にデータの白色化のアイデアを取り入れて2段階最適化問題として解く → **分類正解率の向上**

Methods	A→C	A→D	A→W	C→A	C→D	C→W	D→A	D→C	D→W	W→A	W→C	W→D
OT-EMD	66.67	47.77	45.76	67.52	36.31	42.71	62.17	59.71	85.08	55.41	51.16	96.82
OT-SKH	76.83	75.80	69.83	84.35	78.34	68.14	80.92	71.57	93.90	74.17	67.02	87.26
Proposed	78.70	80.25	69.83	88.21	80.25	68.47	82.74	75.69	97.97	83.49	73.62	98.73

合成関数最小化のための Levenberg-Marquardt 法 [Marumo, Okuno, Takeda, Math. Program., 2024]

考える問題 凸関数と合成関数の和の最小化

$$\min_{x \in \mathbb{R}^d} \{F(x) := g(x) + h(c(x))\}$$

- $g: \mathbb{R}^d \rightarrow \mathbb{R} \cup \{\infty\}$: 凸・シンプル
- $h: \mathbb{R}^n \rightarrow \mathbb{R}$: 凸・平滑
- $c: \mathbb{R}^d \rightarrow \mathbb{R}^n$: 平滑

応用例: 経験損失最小化

$$\min_{x \in \mathbb{R}^d} \frac{1}{N} \sum_{i=1}^N \ell(\phi(a_i; x), b_i)$$

- モデル $\phi(\cdot; x)$ が $c(x)$ に 対応
- 損失関数 ℓ が h に 対応

(一般化) Levenberg-Marquardt (LM) 法

[Levenberg, 1944], [Marquardt, 1963]

$$x_{k+1} = \operatorname{argmin}_{x \in \mathbb{R}^d} \left\{ g(x) + h \left(c(x_k) + \nabla c(x_k)^\top (x - x_k) \right) + \frac{\mu_k}{2} \|x - x_k\|^2 \right\}$$

$c(x)$ の一次近似

本研究の貢献

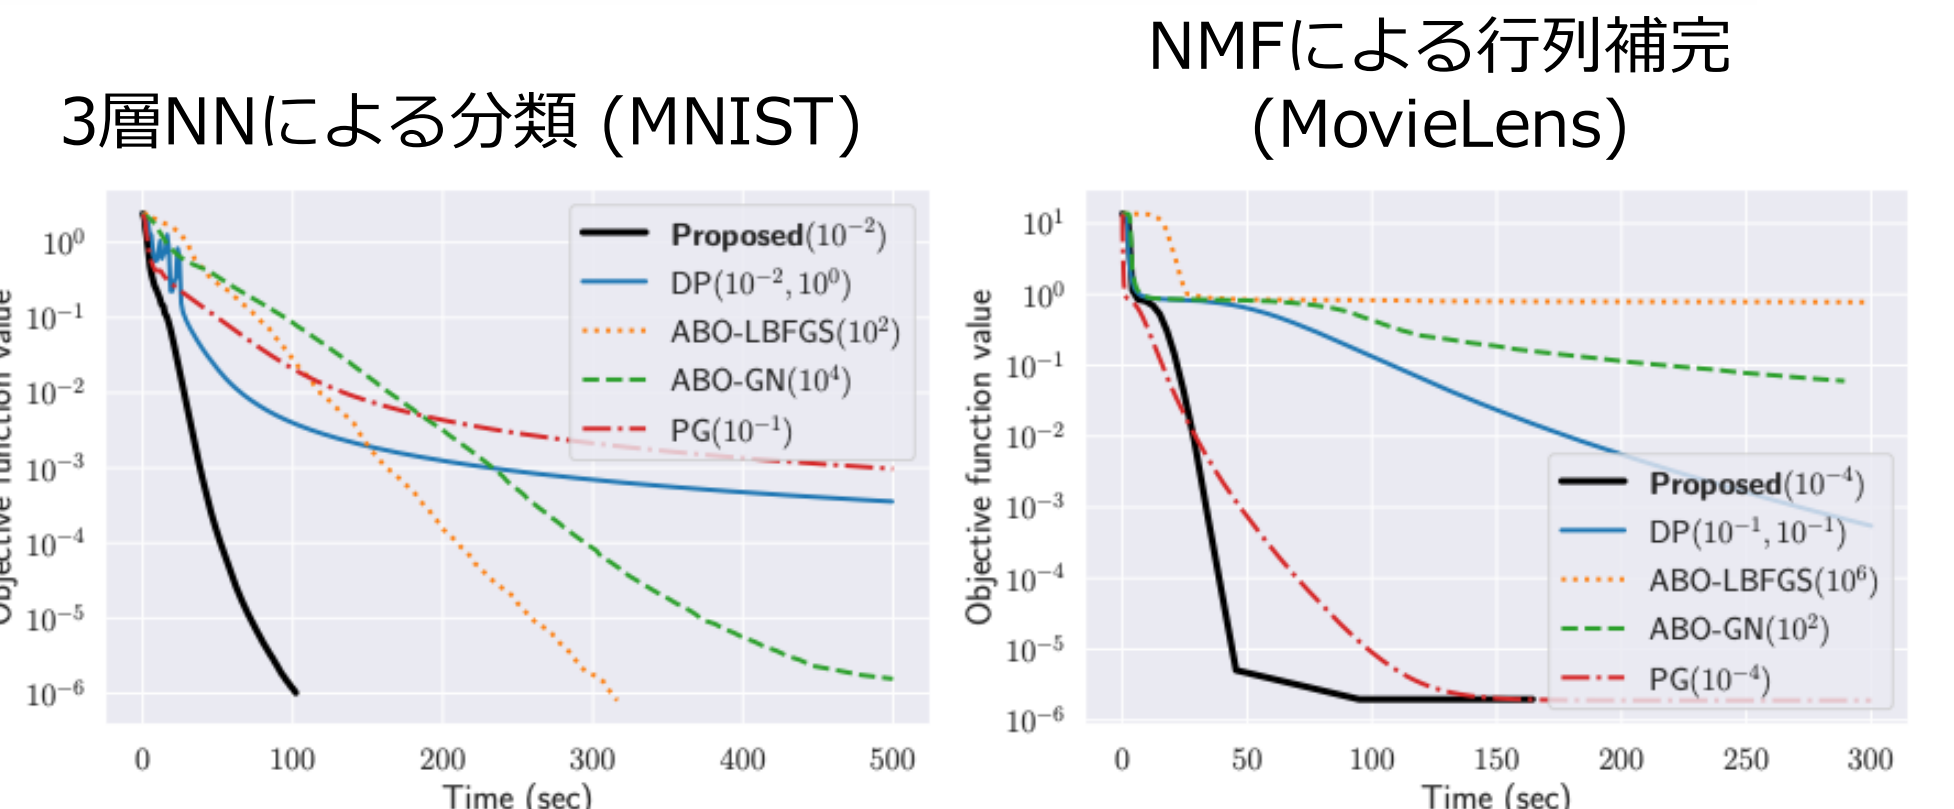
LM法で μ_k を適切に定め 子問題をおる近似条件を満たすように解くことで3つの理論保証「**反復計算量・オラクル計算量・局所二次収束**」を同時に達成

既存手法との比較

h	文献	反復	オラクル	局所
凸 + 尖	[Burke and Ferris, 1995]			✓
凸 + Lip + 尖	[Drusvyatskiy and Lewis, 2018]	✓		✓
凸 + Lip	[Drusvyatskiy and Lewis, 2018]	✓		
凸 + Lip + 平滑	[Drusvyatskiy and Paquette, 2019]	✓	✓	
凸 + 平滑	本研究	✓	✓	✓

数値実験

機械学習やデータ同化の問題例で提案手法(黒線)が既存手法に比べ安定して高速に動く



2段階最適化を用いたハイパーパラメータ選択に対する統一的な平滑化手法 [Alcantara, Nguyen, Okuno, Takeda, Chen, Math. Program., 2025]

ハイパーパラメータ学習を非平滑非凸2段階最適化問題として定式化

$$\begin{aligned} \min_{\omega, \lambda} & f(\omega, \lambda) \\ \text{s.t. } & \omega, \lambda \in \operatorname{argmin}_{\omega \in \mathbb{R}^n} G(\omega, \bar{\lambda}) + \lambda R_1(\omega) \\ & (\lambda, \bar{\lambda}) \in \Omega_\epsilon \subset \mathbb{R}^r, \end{aligned}$$

ただし

$$\begin{aligned} G(\omega, \bar{\lambda}) &:= g(\omega) + \bar{\lambda}^T \bar{R}(\omega) \\ \bar{\lambda} &:= (\lambda_2, \dots, \lambda_r)^T \\ \bar{R}(\omega) &:= (R_2(\omega), \dots, R_r(\omega))^T \end{aligned}$$

$$R_1(\omega) := \sum_{i=1}^n \psi(|\omega_i|^p) \quad (0 < p \leq 1)$$

$\Omega_\epsilon := \{(\lambda, \bar{\lambda}) \in \mathbb{R} \times \mathbb{R}^{r-1} : \lambda \geq \epsilon, \bar{\lambda} \geq 0\}$

非凸 非平滑

提案手法

✓ $R_1(\omega)$ の平滑化近似を利用

$$\varphi_\mu(\omega) := \sum_{j=1}^n \psi([\phi(\mu, \omega_j)]^p)$$

✓ 問題の平滑化緩和

$$\begin{aligned} \min_{\omega, \lambda} & f(\omega) \\ \text{s.t. } & \nabla_\omega G(\omega, \bar{\lambda}) + \lambda \nabla \varphi_\mu(\omega) = 0 \\ & \lambda \in \Omega_\epsilon. \end{aligned}$$

✓ $\mu \downarrow 0$ として半平滑Newton法を適用

Averaged results for $(n, m_2, m_1, p) = (500, 300, 300, 0.5)$ using $\psi(t) = \log(1 + at)$

i	val	bkkt	sparsity(%)	time(s)	success(%)
1	2.06e-03	5.78e-03	80.7	200.4 (4.9)	95
2	2.06e-03	6.00e-03	73.0	211.8 (4.7)	85
3	2.11e-03	5.90e-03	74.9	196.3 (5.2)	85
4	2.06e-03	5.68e-03	79.2	237.3 (6.4)	95

本研究の貢献

✓ **2段階KKT条件**の導入

- 最適性の新たな必要条件
- 既存の条件よりも精緻

✓ 収束性に関する統一的な理論分析

- $\phi(\mu, x)$ を生成する密度関数に基づく分析
- **既存研究より弱い制約想定でより強い収束保証**を証明

Averaged results for $(n, m_2, m_1) = (250, 500, 500)$ using $\psi(t) = t$

p	method	val	test	sparsity(%)	time(s)
1	Algorithm 1 w/ ϕ_1	4.15e-03	4.12e-03	41.7	39.4
	Bayesian Optimization	7.10e+00	6.79e+00	50.4	314.8
0.5	Algorithm 1 w/ ϕ_1	6.60e-04	6.67e-04	72.7	39.9
	Bayesian Optimization	4.47e+01	4.47e+01	19.1	160.8