

Outlier-Robust Neural Network Training: Efficient Optimization of Transformed Trimmed Loss with Variation Regularization (Submitted.)

奥野彰文^{1,2,3}, 柳下翔太郎¹

¹統計数理研究所, ²理研AIP, ³理研CBS


自己紹介

- ▶ 研究遍歴：数理統計 ⇒ 統計的機械学習 ⇒ 統計学一般
- ▶ 学部-博士の指導教員：下平英寿教授.
- ▶ 博士 (情報学, 京都大学, 2020年9月)




統計数理研究所 (立川市, 東京)

Computation (Machine Learning)




WAIC + NN
Okuno and Yano (JCGS2023)


$$\mathbb{E}_T \left(\left\| \frac{\partial}{\partial \theta} d_{\beta}(\hat{Q}, P_{\theta(\tau)}) \right\|_2^2 \right) \xrightarrow{\text{in prob. } 0, (T \rightarrow \infty)}$$




Okuno (2307.05251)




Okuno and Harada (2303.17823)




Okuno et al. (2306.16593)



Okuno and Hattori (2204.08205)
Hattori, Okuno, Roederer (ApJ)



Okuno and Shimodaira (AISTATS2019a)




Okuno et al. (ICML2018)



$$\mathbb{V}(\hat{f}_{n,h}(x, x')) = O(n^{-\min\{2s, 2\beta+s\}/(s+d)})$$

Okuno and Yano (SPL2023)



Okuno et al. (AISTATS2019b)




Mizutani, Okuno et al. (2005.00670)

$$\mathcal{E}(\hat{g}_n) = O(n^{-2\beta/(2\beta+d)})$$

Okuno and Shimodaira (NeurIPS2020)
Cao, Okuno et al. (2112.13951)

$$\inf_{\hat{f}_n} \sup_{f_* \in \mathcal{F}_{INV}^{Lip}} R_{INV}(\hat{f}_n, f_*) \asymp n^{-2/(2+d)}$$

Okuno and Imaizumi (2112.00213)



Case 2: non-convex quadrilateral

Visualization/Integration (Representation Learning)

Theory (Mathematical Statistics)

最近は科学系の人たちとワイワイやっています



THE ASTROPHYSICAL JOURNAL, 946:48 (32pp), 2023 March 20

© 2023. The Author(s). Published by the American Astronomical Society.

OPEN ACCESS

<https://doi.org/10.3847/1538-4357/ach93b>



Finding *r*-II Sibling Stars in the Milky Way with the Greedy Optimistic Clustering Algorithm

Kohei Hattori^{1,2,3}, Akifumi Okuno^{2,4}, and Ian U. Roederer^{3,5}

¹ National Astronomical Observatory of Japan, 2-21-1 Osawa, Mitaka, Tokyo 181-8588, Japan

² The Institute of Statistical Mathematics, 10-3 Midoricho, Tachikawa, Tokyo 190-8562, Japan

³ Department of Astronomy, University of Michigan, 1085 S. University Avenue, Ann Arbor, MI 48109, USA

⁴ RIKEN Center for Advanced Intelligence Project, 1-4-1 Nihonbashi, Chuo-ku, Tokyo, 103-0027, Japan

⁵ Joint Institute for Nuclear Astrophysics—Center for the Evolution of the Elements (JINA-CEE), 640 S. Shaw Lane, East Lansing, MI 48824 USA
Received 2022 July 8; revised 2023 February 3; accepted 2023 February 3; published 2023 March 28

Abstract

R-process enhanced stars with $[\text{Eu}/\text{Fe}] \geq +0.7$ (so-called *r*-II stars) are believed to have formed in an extremely neutron-rich environment in which a rare astrophysical event (e.g., a neutron-star merger) occurred. This scenario is supported by the existence of an ultra-faint dwarf galaxy, Reticulum II, where most of the stars are highly enhanced in *r*-process elements. In this scenario, some small fraction of dwarf galaxies around the Milky Way were *r* enhanced. When each *r*-enhanced dwarf galaxy accreted to the Milky Way, it deposited many *r*-II stars in the Galactic halo with similar orbital actions. To search for the remnants of the *r*-enhanced systems, we analyzed the distribution of the orbital actions

Hattori, Okuno, and Roederer (2023, Astrophysical Journal)

最近は科学系の人たちとワイワイやっています

統計数理核融合



DATA SCIENCE

プラズマ物理と相補的なプラズマデータに対する統計数理モデリング

情報システム研究機構 戦略的研究PJ1
2022-SRP-13


DATA SCIENCE
powered by DALL-E3

プロジェクト概要

「プラズマ物理と相補的なプラズマデータに対する統計数理モデリング」(代表・三分一史和)は大学共同利用機関法人情報・システム研究機構の戦略的研究プロジェクトに採択された、統計数理研究所と核融合科学研究所を中心とした共同研究プロジェクトです。

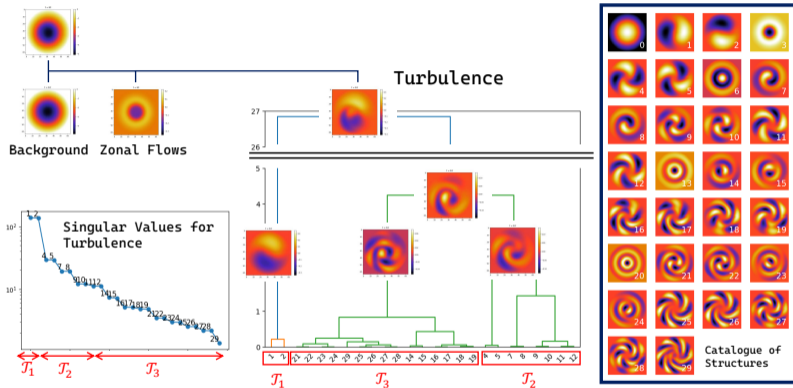
核融合におけるプラズマは極めて高温で複雑な非線形環境にあります。プラズマの基本現象の理解は進んでいるものの、異なる現象の相互作用を統合的に理解し制御することが核融合発電などの実現には不可欠です。世界各国が協力して進めるITERプロジェクトなどがその例です。しかし、プラズマの電流が突然消失する「ディスラプション」など未解明の課題も多くあり、本研究ではデータ駆動アプローチとモデル駆動アプローチを併用してプラズマの挙動の予測・制御を目指します。統計数理的手法を活用し、リアルタイムの予測や乱流データの解析を行います。統計数理コミュニティと核融合科学コミュニティの協力により学術界や産業界への貢献と、それに伴う「統計数理核融合学」の創成を目指しています。

ROIS戦略的研究プロジェクト



<https://statplasma.github.io>

最近は科学系の人たちとワイワイやっています



Okuno, Kodahara, and Sasaki (2024, Plasma and Fusion Research: Rapid Communications)

- ▶ かわいい図がいろいろ作れるので楽しい。

宣伝

▶ 日本統計学会春季集会（3月8日）@筑波大東京キャンパス

AM-B「諸科学における統計学的アプローチ」

10:10~11:50 119教室 **Zoom B**

オーガナイザー:奥野彰文(統計数理研究所), 三分一史和(統計数理研究所),
矢野恵佑(統計数理研究所), 横山雅之(核融合科学研究所)

講演1:服部公平(国立天文台/統計数理研究所)

「天文学における統計科学」

講演2:近藤洋平(名古屋大学)

「生物画像に対する力学系モデリングと逆問題」

講演3:加納将行(東北大学)

「情報科学を用いた測地データ解析と断層すべりモニタリングの高度化」

講演4:森下侑哉(京都大学)

「統計科学を活用した核融合プラズマの理解と予測」

<https://jss2025spring.ywstat.jp/>

▶ ぜひお越しください。

計算系の人たちともワイワイやっています

計算技術による学際的統計解析ワークショップ

開催概要

高度な計算技術を活用した統計手法研究を目指し、計算技術・統計手法に関する研究発表を通じた研究者の交流を目的とします。口頭発表はオンライン配信予定（質疑応答は対面を最優先します）。

- 日時：2025年2月17日・18日。
- 場所：統計数理研究所セミナー室1 (D305)
- オーガナイザ：奥野彰文 (統計研/理研AIP)

[参加登録はこちら](#)

スケジュール

(*口頭発表は全て招待講演)

2月17日

13:00-13:20

奥野彰文 (統計数理研究所)

開催趣旨: 計算技術と統計手法研究の融和を目指して

本ワークショップでは主に統計手法、数値解析、最適化、計算代数など様々な分野で活躍されており、また異分野との交流

- expand -

13:20-14:00

豊田吉彦 (大阪大学)

大規模データに対するクラスタリング法について

大規模データに対しては、k-means法などの単純なクラスタリング法を用いることが多い。しかし、単純な方法では、データの結

- expand -


14:00-14:10 休憩

<https://okuno.net/events/ISACT2025>


Outlier-Robust Neural Network Training

なにをしたのか


▶ 外れ値にロバストかつフレキシブルな予測法の提案




(a) 線形モデル+Huber



(b) NN+Huber



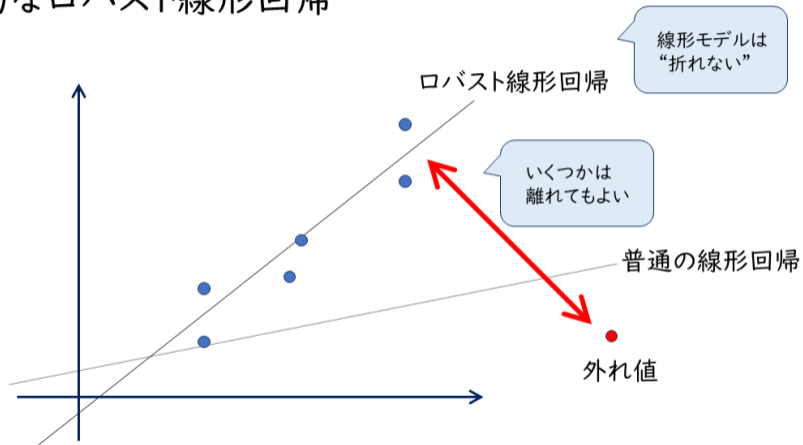
(c) NN+Tukey



(d) 提案法


Figure: $f_*(x) = \sin(2x_1) \cos(2x_2)$.

典型的なロバスト線形回帰




ニューラルネットの学習

(二乗損失)




ニューラルネットの学習 (二乗損失)

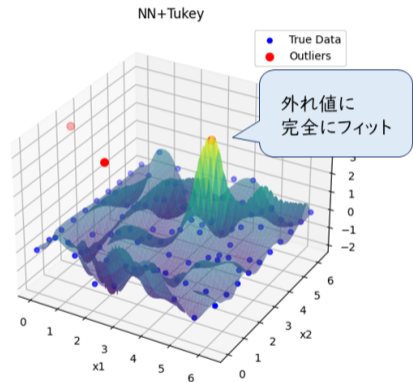
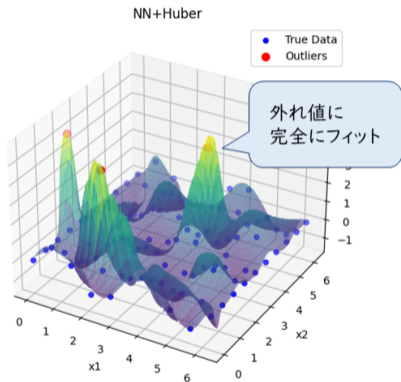


ニューラルネットの学習


(ロバスト損失)



実際のロバスト損失+NN (+勾配法)



我々が本当にやりたかったこと



つまり何が言いたいのかというと

- ▶ 予測関数 $f_{\theta}(x)$ はいい感じにグニャグニャしてほしいが、
- ▶ 過剰にグニャグニャしないでほしい。

予測関数に“硬さ”のようなものを入れたい。

関数の変動を抑える

Higher-Order Variation Regularization (HOVR; Okuno, arXiv:2308.02293v1):

$$C_{k,q}(f_\theta) := \int_{\Omega} \left| \frac{\partial^k f_\theta(x)}{\partial^k x} \right|^q dx.$$

例えば正規直交基底を用いた回帰関数 $f_\theta(x) = \sum_j \theta_j \phi_j(x)$ の場合には,

$$C_{k,2}(f_\theta) \lesssim \|\theta\|_2^2$$

なので、パラメータ正則化の一般化と思える。

- ▶ 導関数は autograd で計算可能.
- ▶ 積分は(明示的に計算せず)確率的に回避できる. 特殊な確率的勾配法.

つまりどうこと?




Figure: $C_{2,2}(f) \approx 0.64$




Figure: $C_{2,2}(f) \approx 197$

- ▶ 激しいグニャグニャを抑制できる.
- ▶ 線形/カーネル回帰モデルなどではパラメータ正則化に対応.
- ▶ ニューラルネットでは???




Figure: Weight decay (要するにリッジ)




Figure: HOVR

- ▶ Akifumi Okuno, “A stochastic optimization approach to train non-linear neural networks with regularization of higher-order total variation”, arXiv:2308.02293v1.
- ▶ 確率的勾配法を用いると，積分型の正則化を厳密に最小化できる。
- ▶ デスクリジェクトされて萎えた。放置 ⇒ 気付いたら1年が経過していました…

残差を $r_i(\theta) := y_i - f_\theta(x_i)$ とし、添え字を並びかえて

$$|r_{(1;\theta)}(\theta)| \leq |r_{(2;\theta)}(\theta)| \leq \cdots \leq |r_{(n;\theta)}(\theta)|$$

とすると,

$$T_h(r(\theta)) = \frac{1}{n} \sum_{i=1}^h r_{(i;\theta)}(\theta)^2$$

を Trimmed Loss と呼ぶ。ロバスト損失として知られている。

- ▶ 柳下さんはこのあたりの最適化にとっても詳しい。

アイデア

- ▶ 合体させると良いのでは・・・？
- ▶ 正則化により過剰なグニャグニャを防ぎ，ロバスト損失で外れ値を無視する。

$$\text{損失関数： } \underbrace{\frac{1}{2} T_h(r(\theta))}_{\text{ロバスト損失}} + \underbrace{\lambda \cdot C_{k,q}(f_\theta)}_{\text{関数を硬くする正則化}}$$

- ▶ (伝統的なロバスト指標である)破局点が多い。
- ▶ 効率的な最適化アルゴリズムが作れる。

効率的な最適化：柳下さんによる技術

- ▶ 余分なパラメータ ξ を入れると、Trimmed Loss T_h とパラメータ θ を分離できる。

Yagishita (arXiv:2410.04554)

$$\frac{1}{2} T_h(r(\theta)) = \underbrace{\min_{\xi \in \mathbb{R}^n} \left\{ \frac{1}{n} \|r(\theta) - \xi\|_2^2 + T_h(\xi) \right\}}_{\text{Transformed Trimmed Loss (TTL)}}$$

- ▶ これは非常に最適化しやすい形になっている。

合体

$$\underbrace{\frac{1}{2} T_h(r(\theta))}_{\text{ロバスト損失}} + \underbrace{\lambda \cdot C_{k,q}(f_\theta)}_{\text{関数を硬くする正則化}} = \min_{\xi} \{U_\lambda(\theta, \xi) - V_h(\xi)\}$$

ただし

$$U_\lambda(\theta, \xi) = \frac{1}{n} \{\|r(\theta) - \xi\|_2^2 + \|\xi\|_2^2\} + \lambda C_{k,q}(f_\theta) \text{ は Nonconvex and smooth,}$$
$$V_h(\xi) = \frac{1}{n} \|\xi\|_2^2 - T_h(\xi) \text{ は Convex and nonsmooth.}$$

つまり Trimmed Loss + HOVR の最小化は、拡張パラメータ (θ, ξ) についての

Augmented and Regularized Trimmed Loss (ARTL)

$$F_{h,\lambda}(\theta, \xi) = U_\lambda(\theta, \xi) - V_h(\xi)$$

の最小化と等しい。最適化手法が作れて、DCアルゴリズム風の収束証明ができる。

最適化アルゴリズムの提案

- ▶ $u_\lambda^{(t)}(\theta^{(t)}, \xi^{(t)})$ は $U_\lambda(\theta)$ の不偏確率勾配,
- ▶ $v_h(\xi)$ は $V_h(\xi)$ の劣勾配とする.
- ▶ $g_{h,\lambda}^{(t)}(\theta, \xi) = u_\lambda^{(t)}(\theta, \xi) - (0, v_h(\xi))$.

Stochastic Gradient-Supergradient Descent (SGSD)

$$(\theta^{(t+1)}, \xi^{(t+1)}) \leftarrow (\theta^{(t)}, \xi^{(t)}) - \omega_t g_{h,\lambda}^{(t)}(\theta^{(t)}, \xi^{(t)}).$$

- ▶ 積分項の問題や微分不可能点の問題を突破して、厳密な収束が示せる.

詳細は省略しますが...

- ▶ θ についての微分可能性は仮定 (e.g., Sigmoid activation)
- ▶ 勾配の不偏性などいくつか仮定.

収束定理のシンプルな形


学習率を $\omega_t = \alpha(1+t)^{-1/2}$ とすると,

$$\mathbb{E} \left[\inf_{v \in \partial V_h(\xi)} \left\| \frac{\partial U_\lambda(\theta^{(\tau_T)}, \xi^{(\tau_T)})}{\partial(\theta, \xi)} - (0, v) \right\|_2^2 \right] = \mathcal{O}(T^{-1/4}(\log T)^{1/2}).$$


- ▶ τ_T はランダムに選択されるStopping Time.
- ▶ (劣勾配の自由度を除いて)勾配が0, つまり停留点に収束する.

というわけで最初の図に戻る.


- ▶ (入力)2次元 - 100 - 100 - 100 - (出力)1次元の多層パーセプトロン.
- ▶ パラメータ数2万超, 外れ値3%混入.




(a) 線形モデル+Huber



(b) NN+Huber











(c) NN+Tukey











(d) 提案法

Figure: $f_*(x) = \sin(2x_1) \cos(2x_2)$.









やってみた 1 (checked)











やってみた 2 (volcano)



やってみた 3 (stripe)



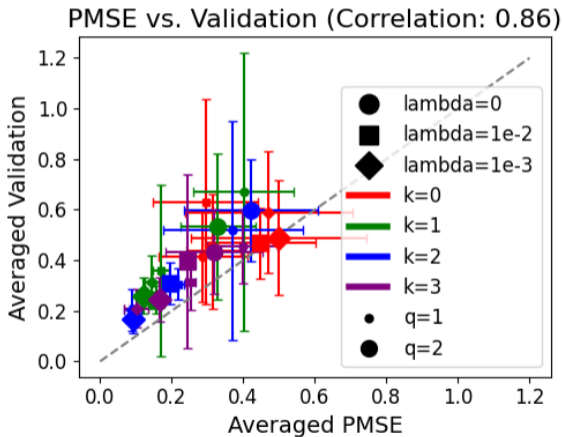
やってみた 4 (plane)



	checkered	Non-linear volcano	stripe	Linear plane
Linear Reg. with Huber's Loss	0.124 (0.004)	0.130 (0.003)	0.498 (0.016)	<u>0.001</u> (0.001)
Linear Reg. with RANSAC	0.140 (0.013)	0.186 (0.058)	0.871 (0.277)	0.001 (0.001)
Support Vector Reg. with RBF Kernel	0.127 (0.008)	0.113 (0.020)	0.508 (0.031)	0.006 (0.002)
NN with Huber's Loss	0.634 (0.608)	1.031 (0.861)	0.488 (0.475)	0.043 (0.025)
NN with Tukey's Loss	0.458 (0.655)	0.413 (0.630)	0.304 (0.395)	0.017 (0.009)
NN with Label Noise Reg.	1.155 (1.068)	0.872 (0.659)	0.561 (0.498)	0.756 (0.945)
NN with RANSAC	0.160 (0.036)	0.142 (0.009)	0.527 (0.018)	0.011 (0.016)
NN with ARTL ($h = 0.9n, k = 1$)	<u>0.088</u> (0.090)	<u>0.082</u> (0.076)	<u>0.223</u> (0.238)	0.010 (0.004)
NN with ARTL ($h = 0.9n, k = 2$)	0.061 (0.016)	0.040 (0.029)	0.119 (0.047)	0.007 (0.001)

パラメータ選択

- ▶ ロバスト損失でValidationすればよい.



おまけ

- ▶ Akifumi Okuno. An integrated perspective of robustness in regression through the lens of the bias-variance trade-off. arXiv:2407.10418

では「ロバストネス」の種類を大きく3つに分類した：

1. 外れ値へのロバストネス (統計学)
2. 入力の摂動に対するロバストネス (最適化)
3. モデルの誤特定へのロバストネス (機械学習).

提案法は (1)トリム損失, (2)HOVR, (3)ニューラルネット, でこの3つをすべて網羅した推定になっている.

まとめ

- ▶ ロバスト損失を使っても、ニューラルネットは外れ値に過適合してしまう。
- ▶ ニューラルネットを“硬くする”正則化としてHOVRを提案。
- ▶ ロバスト損失+正則化と等価なARTLを提案。
- ▶ ARTLを最小化する確率的アルゴリズムSGSDを提案。
- ▶ 収束証明もできたし、その実験結果もよさそうだった。

コメント・ご質問は okuno@ism.ac.jp まで。