

限られた教師情報からの 高精度な予測モデルの構築

原田 達也（東京大学 先端科学技術研究センター）

杉山 将（理化学研究所 革新知能統合研究センター）

目標

- ・ 限られた教師情報からの予測モデルの構築

背景

- ・ 膨大なデータセットの整備, GPGPUなどの高速な計算機の発展, 深層学習等の機械学習技術の成功によって**予測モデルの精度が飛躍的に向上**
 - ・ 画像認識, 音声認識, 翻訳など.

問題点

- ・ **高精度を得るには膨大なラベル付データが必要**
 - ・ 多くの高品質な教師情報付きデータは手作業で作成
 - ・ 大変な時間とコストがかかる
 - ・ 教師データが本質的に得られない問題に適用不可能
 - ・ 熟練した機械学習エンジニアの経験と勘が必要


計画・体制

・ 杉山グループ

- ・ 弱教師付き学習
- ・ ラベル雑音ロバスト学習
- ・ 敵対的攻撃への対処

・ 原田グループ

- ・ 知識転移
- ・ 生成モデルと時空間のモデル化
- ・ 高精度な予測モデルの構築基盤



弱教師付き学習

杉山グループ

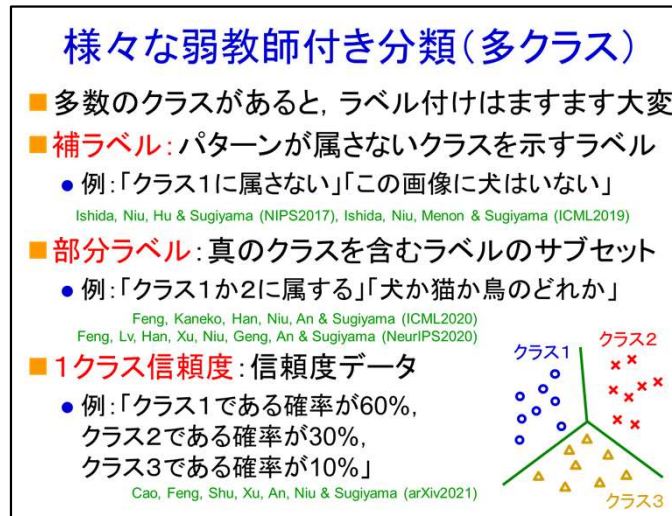


4

■ 背景:

- 教師ラベル付きデータの収集はコスト大
- 教師なし学習は予測性能を保証できない
- 低ラベル付けコストの弱教師データを活用したい

■ 成果:


- 様々な弱教師データから分類リスクを不偏推定できる統一的な枠組みを提案
- 任意のモデル, 正則化, 最適化法と組み合わせ可能な汎用性を持つ
- 教師付き学習と同等の予測性能を理論保証
- 深層学習に対する更なる性能向上機構の導入



Sugiyama, Bao, Ishida, Lu, Sakai & Niu, Machine Learning from Weak Supervision. 320 pages, MIT Press, 2022.

■ 特記事項:

- 令和4年度科学技術分野の文部科学大臣表彰科学技術賞受賞
- MIT Pressより英語専門書を出版
- ACML2019/2020/2021/2022やIJCAI2021にてワークショップを主催



■ 背景:



- 回帰(加法雑音)では雑音は自動的に打ち消し合う
- 分類(ラベル反転)では明示的な雑音除去機構が必要
- 雑音遷移行列が分かれば雑音を系統的に除去できる

Patrini et al. (CVPR2017)

- しかし雑音遷移行列は未知で一般に同定不能

■ 成果:

- 雑音遷移行列の系統的な推定理論
- 雑音遷移行列の同定可能条件の一般化
- 入力依存ラベル雑音への拡張




Xia, Liu, Han, Wang, Gong, Liu, Niu, Tao & Sugiyama (NeurIPS2020), Berthon, Han, Niu, Liu & Sugiyama (ICML2021), Cheng, Liu, Ning, Wang, Han, Niu, Gao & Sugiyama (CVPR2022)

- 超ロバスト「共教示」手法の開発

■ 特記事項:


- ACML2021, IJCAI2021, CIKM2022にて国際チュートリアルを実施
- NeurIPS2018で発表した共教示の論文の引用数が1000回以上



雑音遷移行列の例
(3クラス)

1	0	0
0.1	0.8	0.1
0.5	0.5	0

Han, Yao, Niu, Zhou, Tsang, Zhang & Sugiyama (NeurIPS2018), Xia, Liu, Wang, Han, Gong, Niu & Sugiyama (NeurIPS2019), Yao, Liu, Han, Gong, Deng, Niu, Sugiyama & Tao (NeurIPS2020), Zhang, Niu & Sugiyama (ICML2021), Li, Liu, Han, Niu & Sugiyama (ICML2021)



Han, Yao, Yu, Niu, Xu, Hu, Tsang & Sugiyama (NeurIPS2018), Yu, Han, Yao, Niu, Tsang & Sugiyama (ICML2019), Han, Niu, Yu, Yao, Xu, Tsang & Sugiyama (ICML2020)

敵対的攻撃への対処

■ 背景:


- ニューラルネットはテスト入力の微小な摂動に弱い
- 自動運転や医用画像処理などでの悪用が懸念
- 敵対的学習によってロバスト性が向上
- 脆弱性のメカニズムを解明し、対処法を開発したい

■ 成果:

- 様々な攻撃手法・防御手法の性質を理論的・実験的に分析・評価し、分類問題に対するロバスト性を向上
 - 敵対的攻撃に対する理論保証付き防御法
 - 敵対的学習による過度な保守性の回避
 - 敵対的攻撃に対してロバストな表現学習
 - 敵対的攻撃に対してロバストなアーキテクチャの探索
 - 敵対的攻撃の検出
- 分類以外のシナリオへの拡張
 - 画像の雑音除去における敵対的攻撃・防御の解析
 - 二標本検定に対する敵対的攻撃・防御の解析

■ 現状の課題:

- 理論保証を持った防御法は実用的でない
- 実用的な防御法は、すぐに新たな攻撃法が登場
- 分類以外の様々なタスクでも脆弱性が見つかる



$$\min_f \sum_{i=1}^n \ell(f(\tilde{x}_i), y_i)$$
$$\tilde{x}_i = \arg \max_{\tilde{x} \in B(x_i)} \ell(f(\tilde{x}), y_i)$$

The diagram illustrates the definition of an adversarial perturbation $\tilde{x}_i$ as the point that maximizes the loss $\ell(f(\tilde{x}), y_i)$ within a neighborhood $B(x_i)$ of the input x_i .

Tsuzuku, Sato & Sugiyama (NeurIPS2018)
Hu, Niu, Sato & Sugiyama (ICML2018)
Ni, Charoenphakdee, Honda & Sugiyama (NeurIPS2019)
Bao, Scott & Sugiyama (COLT2020)
Zhang, Xu, Han, Niu, Cui, Sugiyama & Kankanhalli (ICML2020)
Zhang, Zhu, Niu, Han, Sugiyama & Kankanhalli (ICLR2021)
Du, Zhang, Han, Liu, Rong, Niu, Huang, & Sugiyama (ICML2021)
Gao, Liu, Zhang, Han, Liu, Niu & Sugiyama (ICML2021)
Yan, Zhang, Niu, Feng, Tan & Sugiyama (ICML2021)
Wang, Liu, Han, Liu, Gong, Niu, Zhou & Sugiyama (NeurIPS2021)
Yan, Zhang, Feng, Sugiyama & Tan (IJCAI2022)
Xu, Zhang, Liu, Sugiyama & Kankanhalli (ICML2022)
Zhang, Xu, Han, Liu, Niu, Cui & Sugiyama (TMLR2022)
Cui, Zhang, Liang, Han, Sugiyama & Zhang (NeurIPS2022)
Zhou, Zhu, Zhang, Liu, Niu, Han & Sugiyama (NeurIPS2022)
Mo, Wu, Wang, Guo & Wang (NeurIPS2022)


□教師無しドメイン適応 (UDA)

- ソースドメインからターゲットドメインへの知識転移。ソースドメインのみラベルを持つ。ターゲットドメインはラベルを持たない。
- Tri-training, **Maximum Classifier Discrepancy** [Saito+ ICML2017, CVPR2018, ICLR2018]
- 物体認識 [Saito+ CVPR2019]
- オープンセット認識 [Saito+ ECCV2018]
- ドメイン汎化 [Matsuura+ AAAI2020]
- カテゴリ分類器と敵対的ドメイン分類器の密な結合 [Thomas+ WACV2023]
- 結合誤差の最小化 [Zhang+ submitted]



□ソースデータを利用しない教師無しドメイン適応



- ソースデータやソースモデルパラメータに直接アクセスしない。プライバシーとセキュリティの担保。 [Yeh+ WACV2021], [Yang+ IEEE TIP2022]
- 対象データの分類信頼度に応じた特徴量分布のアライメント [Yeh+ ICPR2022]



□ **特記事項:** Maximum Classifier Discrepancy (CVPR2018) attracted 1300+ citations.



ロノイズに頑健な生成モデル [Kaneko+ CVPR2020] [Kaneko+ CVPR2021]

- 通常のGANを利用した場合、ブラー、ノイズ、圧縮などの画像劣化にもかかわらずデータに含まれるノイズも模倣してしまう。
- 提案手法では、劣化パラメータ（ぼかしの種類、ノイズの量など）を知らなくても、劣化した画像からきれいな画像を生成可能。




超高効率な生成モデル [Kamata+ AAAI2022]

- スパイキングニューラルネットワーク（SNN）は、その高速性と低消費電力性から注目されているが、生成モデルの研究は進んでいない。
- 専用デバイスを利用した場合：~100倍 高速，~1/100,000倍 低消費電力
- SNNを用いた変分Autoencoderを提案：Fully Spiking Variational Autoencoder (FSVAE)
- 提案するFSVAEは、同じアーキテクチャのANN VAEよりも高品質な画像を生成可能



- 微分可能レンダラー [Kato+ CVPR2018]
- 非剛体物体トラッキング [Li+ CVPR2020, IROS2020]
- 部分点群マッチング・レジストレーション [Li+ CVPR2022, NeurIPS2022]



Results on NeRF-synthetic dataset

□ パーツ分解

[Kawana+ NeurIPS2020, ECCV2022]

□ 制御可能NeRF


[Noguchi+ ICCV2021, CVPR2022, ECCV2022] [Xu+ ECCV2022]



Sparse multi-view video



Novel pose and view synthesis



Structure



Parts



□ 特記事項

- Neural Mesh Renderer (CVPR2018) attracted 700+ citations.
- Oral presentations, CVPR2020, CVPR2022, ECCV2022 (acceptance rate= 2~4%)

- ブラウザ上での高速な機械学習フレームワーク (**WebDNN**) [Hidaka+ ACMMM2017, ICLRW2017]
- 特別なソフトウェアやライブラリのインストール不要
- スマートホンやラップトップ等あらゆるデバイスを特別な設定せずに計算資源として活用可能
- 背景：エッジサイドデバイスの大幅な性能向上

□ AIP加速課題

- 分散学習の実現
- データを集めない機械学習モデル
- 分散した知的モデルの統合による高度な予測
- 杉山グループ、原田グループの手法統合



双曲空間

11

- 双曲面模型

- 一定の負の曲率のリーマン多様体

$$\mathbb{H}_c^n = \{\mathbf{x} \in \mathbb{R}_1^{n+1} \mid c\langle \mathbf{x}, \mathbf{x} \rangle_{\mathcal{L}} = -1, x_0 > 0\}$$

$$\langle \mathbf{x}, \mathbf{y} \rangle_{\mathcal{L}} = \mathbf{x}^\top \mathbf{g}_{\mathcal{L}} \mathbf{y} \text{ for } \forall \mathbf{x}, \mathbf{y} \in \mathbb{R}_1^{n+1},$$

where $\mathbf{g}_{\mathcal{L}} = \text{diag}(-1, \mathbf{1}_n^\top)$


- Poincaré球体模型

$$\mathbb{B}_c^n = \{\mathbf{x} \in \mathbb{R}^n \mid c\|\mathbf{x}\|^2 < 1\}:$$


an open ball of radius $c^{-\frac{1}{2}}$

- 双曲空間のメリット

- 木構造や階層構造の表現に最適
- 原点距離に関して **指数関数的に空間体積が増大**
- 木のノード数は、その深さに応じて指数関数的に増加



2-D Poincaré ball model



[Nickel+ NIPS 2017]

M.C.Escher, Circle Limit III




<https://www.wikiart.org/en/m-c-escher/circle-limit-iii>

- 双曲空間はユークリッド空間とは計量が異なるため、そのままではベクトル演算を適用できない。

- ユークリッド空間：ベクトル空間
- Poincaré球体模型：Möbius Gyrovector空間

• Möbiusの加算

$$x \oplus_c y = \frac{(1 + 2c\langle x, y \rangle + c\|y\|^2)x + (1 - c\|x\|^2)y}{1 + 2c\langle x, y \rangle + c^2\|x\|^2\|y\|^2},$$



<https://geoopt.readthedocs.io/en/latest/extended/stereographic.html>

• Möbius スカラ 積

$$r \otimes_c x = \frac{1}{\sqrt{c}} \tanh^{-1} (r \tanh (\sqrt{c} \|x\|)) [x] = \exp_0^c (r \log_0^c (x)).$$

• Möbius Gyration

$$\text{gyr}[x, y] : z \mapsto z - 2c \frac{(c\langle x, z \rangle \|y\|^2 - \langle y, z \rangle (1 + 2c\langle x, y \rangle))x + (c\langle y, z \rangle \|x\|^2 + \langle x, z \rangle)y}{1 + 2c\langle x, y \rangle + c^2\|x\|^2\|y\|^2}.$$

• Möbius cooperation


$$x \boxplus_c y = x \oplus_c \text{gyr}[x, \ominus_c y]y = \frac{(1 - c\|y\|^2)x + (1 - c\|x\|^2)y}{1 - c^2\|x\|^2\|y\|^2}.$$

Poincaré 球体模型

- 指数写像と対数写像 [Ganea+ 2018]

$$\exp_x^c(v) = x \oplus_c \frac{1}{\sqrt{c}} \tanh\left(\frac{\sqrt{c}\lambda_x^c \|v\|}{2}\right) [v], \quad \forall x \in \mathbb{B}_c^n, v \in \mathcal{T}_x \mathbb{B}_c^n.$$

$$\log_x^c(y) = \frac{2}{\sqrt{c}\lambda_x^c} \tanh^{-1}(\sqrt{c} \|\ominus_c x \oplus_c y\|) [\ominus_c x \oplus_c y], \quad \forall x, y \in \mathbb{B}_c^n.$$



[Chami+ 2020]

- 任意の2点間のPoincaré 距離 [Ganea+ 2018]

$$d_c(x, y) = \frac{2}{\sqrt{c}} \tanh^{-1}(\sqrt{c} \|\ominus_c x \oplus_c y\|) = \|\log_x^c(y)\|_x^c.$$




- 点とPoincaré 超平面との距離 [Ganea+ 2018]

$$\begin{aligned} \tilde{H}_{a,p}^c &= \{x \in \mathbb{B}_c^n \mid \langle \log_p^c(x), a \rangle_p^c = 0\} = \exp_p^c(\{a\}^\perp) \\ &= \{x \in \mathbb{B}_c^n \mid \langle \ominus_c p \oplus_c x, a \rangle = 0\}. \end{aligned}$$

$$d_c(x, \tilde{H}_{a,p}^c) := \inf_{w \in \tilde{H}_{a,p}^c} d_c(x, w) = \frac{1}{\sqrt{c}} \sinh^{-1} \left(\frac{2\sqrt{c} |\langle \ominus_c p \oplus_c x, a \rangle|}{(1 - c \|\ominus_c p \oplus_c x\|^2) \|a\|} \right).$$

- 平行移動 [Ungar 2008]



$$\ominus_c y \oplus_c z = \text{gyr}[y, \ominus_c x] (\ominus_c x \oplus_c w).$$



Hyperbolic Neural Networks++

R. Shimizu, Y. Mukuta, T. Harada. Hyperbolic Neural Networks++. ICLR2021.

	$\mathbb{B}_c^n$
Weighted centroid	★
Function apply	✓
Fully-connected layer	★
Multinomial logistic regression (SoftMax)	★
RNN and GRU	✓
Split and concatenation	★
Convolutional layer	★
(Fully hyperbolic) attention mechanism	★



<http://peterbloem.nl/blog/transformers>

双曲多項ロジスティック回帰

- ユークリッド空間での多項ロジスティック回帰


$$p(y = k | \mathbf{x}) \propto \exp(v_k(\mathbf{x})), \text{ where } v_k(\mathbf{x}) = \langle \mathbf{a}_k, \mathbf{x} \rangle - b_k, \mathbf{a}_k \in \mathbb{R}^n, b_k \in \mathbb{R}.$$

- 法線ベクトルのノルム $\|\mathbf{a}\|$ と識別面との符号付き距離 $D(\mathbf{x}, H_{\mathbf{a}, \mathbf{p}})$ の積に分解

[Lebanon+ 2004]

$$\langle \mathbf{a}, \mathbf{x} \rangle + b = \langle -\mathbf{p} + \mathbf{x}, \mathbf{a} \rangle = \|\mathbf{a}\| \cdot D(\mathbf{x}, H_{\mathbf{a}, \mathbf{p}})$$

where $b = \langle -\mathbf{p}, \mathbf{a} \rangle$





- クラスごとにパラメータを $2n$ から $n+1$ に削減
 - ユークリッドMLRと同じ次元

[Shimizu+ 2021]

双曲MLR

$$v_k(\mathbf{x}) = \text{sign}(\langle \mathbf{a}_k, \ominus_c \mathbf{q}_{\mathbf{a}_k, r_k} \oplus_c \mathbf{x} \rangle) d_c(\mathbf{x}, \bar{H}_{\mathbf{a}_k, r_k}^c) \|\mathbf{a}_k\|_{\mathbf{q}_{\mathbf{a}_k, r_k}}^c,$$

$$\text{where } \mathbf{q}_{\mathbf{a}_k, r_k} = \exp_0^c(r_k[\mathbf{a}_k]), \bar{H}_{\mathbf{a}_k, r_k}^c := \{\mathbf{x} \in \mathbb{B}_c^n \mid \langle \mathbf{a}_k, \ominus_c \mathbf{q}_{\mathbf{a}_k, r_k} \oplus_c \mathbf{x} \rangle = 0\}$$

(a) Reformulation in $\mathbb{R}^n$ (b) Generalization to $\mathbb{B}_c^n$

- ユークリッド空間における全結合層

$$\mathbf{y} = \mathbf{A}\mathbf{x} - \mathbf{b}, \text{ where } \mathbf{y}, \mathbf{b} \in \mathbb{R}^m, \mathbf{x} \in \mathbb{R}^n$$

$$y_k = \langle \mathbf{a}_k, \mathbf{x} \rangle - b_k, \text{ where } \mathbf{x}, \mathbf{a}_k \in \mathbb{R}^n, b_k \in \mathbb{R}$$

- アフィン変換の一般化として双曲MLR 関数へ拡張

- 出力スコア y_k を, 原点を含み出力空間 $\mathbb{R}^m$ の k 番目の軸と直交する超平面からの符号付き距離として扱う.

$$d_c(\mathbf{y}, \bar{H}_{\mathbf{e}^{(k)}, 0}^c) = v_k(\mathbf{x}).$$

$$\bar{H}_{\mathbf{e}^{(k)}, 0}^c = \{\mathbf{x} = (x_1, x_2, \dots, x_m)^\top \in \mathbb{B}_c^m \mid \langle \mathbf{e}^{(k)}, \mathbf{x} \rangle = x_k = 0\},$$



双曲全結合層


$$\mathbf{y} = \mathcal{F}^c(\mathbf{x}; \mathbf{Z}, \mathbf{r}) := \mathbf{w}(1 + \sqrt{1 + c\|\mathbf{w}\|^2})^{-1}, \text{ where } \mathbf{w} := (c^{-\frac{1}{2}} \sinh(\sqrt{c} v_k(\mathbf{x})))_{k=1}^m.$$

$$\mathbf{Z} = \{\mathbf{z}_k \in \mathcal{T}_0 \mathbb{B}_c^n = \mathbb{R}^n\}_{k=1}^m \quad \mathbf{r} = \{r_k \in \mathbb{R}\}_{k=1}^m$$


- 入力空間をより意味のある形で分離することができる.

- 識別超平面は測地線の集合になる.

[Shimizu+ 2021]



(a) $\exp_0^c(\mathbf{A} \log_0^c(\mathbf{x})) \oplus_c \mathbf{b}$



(b) $\mathcal{F}^c(\mathbf{x}; \mathbf{Z}, \mathbf{r})$ (ours)

• MLR分類能力の検証

- WordNetの名詞階層の2値分類
- 安定した学習, 同等の高い性能, パラメータに関して効率的

Test F1 scores for four sub-trees of the WordNet noun hierarchy. Note that the number of parameters of the Euclidean MLR and our approach is $D+1$, whereas for the MLR layer of HNNs, it is $2D$.

RootNode	Model	D=2	D=3	D=5	D=10
animal.n.01 3218 / 798	Unidirectional (ours)	60.69$\pm$4.05	67.88 $\pm$ 1.18	86.26$\pm$4.66	99.15 $\pm$ 0.46
	HNNs	59.25 $\pm$ 16.88	70.59$\pm$1.38	85.89 $\pm$ 3.77	99.34$\pm$0.39
	Euclidean	39.96 $\pm$ 0.89	60.20 $\pm$ 0.89	66.20 $\pm$ 2.11	98.33 $\pm$ 1.12
group.n.01 6649 / 1727	Unidirectional (ours)	74.27 $\pm$ 1.50	63.90 $\pm$ 6.46	84.36 $\pm$ 1.79	85.60 $\pm$ 2.75
	HNNs	76.69$\pm$1.82	66.79$\pm$1.12	84.44$\pm$1.88	86.87$\pm$1.26
	Euclidean	47.65 $\pm$ 0.65	55.15 $\pm$ 0.97	71.21 $\pm$ 1.81	81.01 $\pm$ 1.81
mammal.n.01 953 / 228	Unidirectional (ours)	63.48$\pm$3.76	94.98 $\pm$ 3.87	99.30$\pm$0.30	99.17$\pm$1.55
	HNNs	46.96 $\pm$ 13.86	95.18$\pm$4.19	98.89 $\pm$ 1.29	98.75 $\pm$ 0.51
	Euclidean	15.78 $\pm$ 0.66	36.88 $\pm$ 3.83	60.53 $\pm$ 3.27	65.63 $\pm$ 2.93
location.n.01 2689 / 673	Unidirectional (ours)	42.60$\pm$2.69	66.70$\pm$2.67	78.18$\pm$5.96	92.34$\pm$1.84
	HNNs	42.57 $\pm$ 5.03	62.21 $\pm$ 26.44	77.26 $\pm$ 2.02	85.14 $\pm$ 2.86
	Euclidean	34.50 $\pm$ 0.34	31.44 $\pm$ 0.76	63.86 $\pm$ 2.18	82.99 $\pm$ 3.35

• 畳み込みSequence to Sequenceモデリング

- ポアンカレ畳み込み層の性能を確認
- WMT'17の英語-ドイツ語の機械翻訳
- より少ない次元で大幅な改善

BLEU-4 scores on the test sets newstest2013. The target sentences were decoded using beam search with a beam size of five. D indicates the dimensions of token embeddings and the final MLR layer.

Model	D=16	D=32	D=64	D=128	D=256
ConvSeq2Seq	2.68	8.43	14.92	20.02	21.84
Ours	9.81	14.11	16.95	19.40	21.76

限られた教師情報からの高精度な予測モデルの構築

□弱教師付き学習

- 様々な弱教師付き学習に対応する統一的なフレームワークを提唱
 - 任意の分類器，正則化器，最適化器を利用可能
 - 教師付き学習と同等の予測性能を理論保証

□ラベル雑音ロバスト学習

- 雑音繊維行列の推定理論とアルゴリズム
- 入力依存のノイズに対する拡張
- 超ロバストな「共教示」手法

□敵対的攻撃への対処

- 様々な攻撃手法・防御手法の性質を理論的・実験的に分析・評価
- 分類問題に対するロバスト性を向上
- 画像の雑音除去や二標本検定に対する敵対的攻撃・防御の解析

□知識転移

- 結合誤差を考慮した教師なしドメイン適応
- ソースデータやパラメータを直接利用しないプライバシーに配慮した教師なしドメイン適応

□生成モデルと時空間のモデル化

- ノイズにロバストな生成モデル
- SNNを利用した生成モデル
- 視覚情報からの非剛体物体のモデル化

□高精度な予測モデルの構築基盤

- 環境非依存の分散型機械学習フレームワークの実現と成果の統合
- 双曲ニューラルネットワーク